

Conocimiento y Razonamiento Computacional

Francisco Cantú

Rocío Aldeco

(Editores)



ACADEMIA MEXICANA DE COMPUTACIÓN, A, C.

Conocimiento y Razonamiento Computacional

En colaboración con la Academia Mexicana de Computación:

Editores: Francisco J. Cantú Ortiz y Rocío Aldeco-Pérez.

Colaboradores capítulos 1: Francisco J. Cantú Ortiz.

Colaboradores capítulo 2: Pedro Bello López, Guillermo De Ita Luna, José Antonio Hernández Servín y José Raymundo Marcial-Romero.

Colaboradores capítulo 3: L. Enrique Sucar y Juan Manuel Ahuactzin.

Colaboradores capítulo 4: Ana Carmen Estrada Real y Nora Patricia Hernández López.

Colaboradores capítulos 5: L. Enrique Sucar.

Colaboradores capítulo 6: Rocío Aldeco-Pérez, María Auxilio Medina Nieto, José Alfredo Sánchez Huitrón, María Josefa Somodevilla García, María de la Concepción Pérez de Celis Herrero, Yolanda Margarita Fernández Ordóñez y Reyna Carolina Medina Ramírez.

Colaboradores capítulo 7: Rosa María Valdovinos Rosas y Gerardo Abel Laguna Sánchez.

Colaborador capítulo 8: Francisco J. Cantu, Rocío Aldeco-Pérez y Carlos Zozaya

Segunda edición: 2019

Academia Mexicana de Computación, A. C.

Todos los derechos reservados conforme a la ley.

ISBN: 978-607-97357-3-9

Corrección de estilo: Rocío Aldeco-Pérez.

Diseño de portada: Mario Alberto Vélez Sánchez.

Cuidado de la edición: Luis Enrique Sucar Succar.

Este libro se realizó con el apoyo del CONACyT, Proyecto I1200/28/2019.

Queda prohibida la reproducción parcial o total, directa o indirecta, del contenido de esta obra, sin contar con autorización escrita de los autores, en términos de la Ley Federal del Derecho de Autor y, en su caso, de los tratados internacionales aplicables.

Impreso en México.

Printed in Mexico.

Conocimiento y Razonamiento Computacional

Con la colaboración de

Juan Manuel Ahuactzin

Rocío Aldeco-Pérez

Pedro Bello López

Francisco J. Cantu

Guillermo De Ita Luna

Ana Carmen Estrada Real

Yolanda Margarita Fernández Ordóñez

Nora Patricia Hernández López

José Antonio Hernández Servín

Gerardo Abel Laguna Sánchez

José Raymundo Marcial-Romero

María Auxilio Medina Nieto

Reyna Carolina Medina Ramírez

María de la Concepción Pérez de Celis Herrero

José Alfredo Sánchez Huitrón

María Josefa Somodevilla García

L. Enrique Sucar

Rosa María Valdovinos Rosas

Carlos Zozaya

Agradecimientos

Agradecemos a la Academia Mexicana de Computación, en especial a los integrantes que colaboraron con el desarrollo del libro: Juan Manuel Ahuactzin, Rocío Aldeco-Pérez, Pedro Bello López, Francisco J. Cantu, Guillermo De Ita Luna, Ana Carmen Estrada Real, Yolanda Margarita Fernández Ordóñez, Nora Patricia Hernández López, José Antonio Hernández Servín, Gerardo Abel Laguna Sánchez, José Raymundo Marcial-Romero, María Auxilio Medina Nieto, Reyna Carolina Medina Ramírez, María de la Concepción Pérez de Celis Herro, José Alfredo Sánchez Huitrón, María Josefa Somodevilla García, L. Enrique Sucar, Rosa María Valdovinos Rosas y Carlos Zozaya, por sus valiosas colaboraciones y el tiempo dedicado a esta libro. Agradecemos especialmente Francisco J. Cantú por su coordinación en este proceso y el especial apoyo recibido por parte de L. Enrique Sucar.

Agradecemos al CONACyT por su apoyo para la creación de esta obra.

Prólogo

Este libro se publica en un momento en donde la información que produce una sola persona por año es el equivalente a la contenida en 250 libros. A diferencia de un libro, esta información se genera en una gran diversidad de formatos y proviene de diferentes fuentes. Por ejemplo, podemos mandar un email desde nuestra computadora pero también enviar un mensaje de voz desde nuestro celular a través de alguna aplicación.

Para la comunidad de ciencias computacionales, toda esta información representa conocimiento que puede ser explotado en beneficio de nuestra sociedad. Para lograr esto, dicho conocimiento debe representarse de maneras que las computadoras puedan entender para que posteriormente pueda ser usado para generar nuevo conocimiento.

La forma en que este conocimiento puede ser representado para posteriormente razonar sobre el, es el contenido principal de este libro. Esto es hecho de una forma amena de la mano de reconocidos investigadores mexicanos. Cada uno de ellos, especialistas en estas áreas, nos dan una introducción accesible a como el conocimiento es representado y generado en el área de inteligencia artificial, describiendo los avances de esta área en México y los retos actuales para la comunidad de ciencias computacionales en nuestro país. El último capítulo resume el impacto de la inteligencia artificial en diversos sectores claves de

la sociedad, mostrando la importancia que estos temas tienen en la actualidad. Nuestro país y nuestra sociedad no son la excepción, y este libro es un primer paso para que los lectores conozcan a profundidad estos temas, a los expertos y a las instituciones pioneras en nuestro país.

Felicitemos a todos los involucrados en esta obra y a la Academia Mexicana de Computación, esperamos sea de gran utilidad para docentes, estudiantes y público en general.

Dra. Rocío Aldeco-Pérez

Abreviaturas

<i>IA</i>	Inteligencia Artificial
<i>SMA</i>	Sistema Multi-Agente
<i>WWW</i>	World Wide Web
<i>KDD</i>	Knowledge Discovery Database
<i>KRR</i>	Knowledge Representation and Reasoning
<i>AAAI</i>	Asociación para el Avance de la Inteligencia Artificial
<i>MIT</i>	Massachusetts Institute of Technology
<i>IIIA-CSIC</i>	Instituto de Investigación en Inteligencia Artificial - Consejo Superior de Investigaciones Científicas de España
<i>VSLAM</i>	Visual Simultaneous Location and Mapping
<i>TD</i>	Transformación Digital
<i>ITU</i>	International Telecommunication Union
<i>WWW</i>	World Wide Web
<i>W₃C</i>	World Wide Web Consortium
<i>SMLA</i>	Sociedad Mexicana de Inteligencia Artificial
<i>RNIA</i>	Reunión Nacional de Inteligencia Artificial
<i>ISAI</i>	Symposium Internacional de Inteligencia Artificial
<i>MANOVA</i>	Análisis de Varianza Multivariable

<i>MICAI</i>	Mexican International Conference on Artificial Intelligence
<i>IJCAI</i>	International Joint Conference on Artificial Intelligence
<i>VRP</i>	Vehicle Routing Problem
<i>TS</i>	Tabu Search
<i>PCA</i>	Principal Component Analysis
<i>LLA</i>	Local Linear Approximation
<i>ARN</i>	Acido RiboNucleico
<i>MLE</i>	Estimación de Máxima Verosimilitud
<i>ITS</i>	Sistema de Tutor Inteligente
<i>SBP</i>	Partición Binaria Secuencial
<i>INE</i>	Instituto Nacional Electoral
<i>PDP</i>	Parallel Distributed Processing
<i>DBSCAN</i>	Density-based spatial clustering of applications with noise
<i>IR</i>	Information Retrieval
<i>CBN</i>	Redes Bayesianas Causales
<i>fNIRS</i>	Espectrografía Funcional Infrarroja Cercana
<i>SEMMA</i>	Sample, Explore, Modify, Model, Assess
<i>CRISP-DM</i>	Cross Industry Standard Process for Data Mining
<i>SVM</i>	Máquinas de Vectores de Soporte

<i>RDF</i>	Resource Description Framework
<i>XML</i>	Extensible Markup Language
<i>OWL</i>	Web Ontology Language
<i>FOAF</i>	Friend of a Friend
<i>RI</i>	Repositorios Institucionales
<i>IES</i>	Institución de Educación Superior
<i>LDA</i>	Latent Dirichlet Allocation

Índice general

Índice general	XI
1. Introducción	I
1.1. Establecimiento de la IA y el Enfoque Simbólico	2
1.2. Tecnologías de Inteligencia Artificial	3
1.2.1. Razonamiento Lógico	5
1.2.2. Razonamiento Semántico	6
1.2.3. Razonamiento Probabilístico y Modelos Causales	7
1.2.4. Razonamiento Estadístico	8
1.2.5. Ciencia y Analítica de Datos	8
1.2.6. Sistemas Multiagente	9
1.3. Investigación en México	9
Bibliografía	II
2. Lógica Proposicional y de Predicados	13
2.1. Introducción	13
2.1.1. Conceptos básicos	15
2.2. Estado del arte	16
2.2.1. SAT y SAT incremental	16

2.2.2.	Transición de fase	20
2.2.3.	Revisión de creencias	21
2.3.	Conclusiones	28
	Bibliografía	28
3.	Razonamiento Probabilístico	39
3.1.	Introducción	39
3.2.	Modelos Gráficos Probabilistas	40
3.2.1.	Redes Bayesianas	40
3.2.2.	Programación Bayesiana	42
3.2.3.	Clasificadores Bayesianos	43
3.2.4.	Modelos Dinámicos	45
3.3.	Principales Desarrollos en México	50
3.3.1.	Academia	50
3.3.2.	Gobierno, industria y empresas	52
3.4.	Retos y Perspectivas Futuros	58
	Bibliografía	58
4.	Razonamiento estadístico	63
4.1.	Introducción	63
4.2.	¿Qué es el razonamiento estadístico?	65
4.2.1.	Cómo pensar estadísticamente	65
4.2.2.	Incertidumbre y probabilidad en el razonamiento estadístico	67
4.3.	La estadística en la revolución de la ciencia de datos	69
4.4.	La estadística en el aprendizaje a máquina	71
4.4.1.	Reducción de dimensión: métodos estadísticos	71

4.4.2.	Aprendizaje supervisado	72
4.4.3.	Aprendizaje no supervisado	76
4.4.4.	Evaluación de los métodos de aprendizaje de máquina	78
4.5.	¿Cómo representar el conocimiento?	80
4.6.	Herramientas para análisis estadístico y visualización de datos	82
4.7.	Trabajos relacionados	85
4.8.	Investigación en México	89
4.9.	Conclusiones	93
	Bibliografía	94
5.	Modelos y Razonamiento Causal	103
5.1.	Introducción	103
5.2.	Desarrollo de los modelos casuales	104
5.3.	Modelos gráficos causales	106
5.4.	Descubrimiento causal	112
5.5.	Principales desarrollos en México	114
5.6.	Retos y Perspectivas Futuros	115
	Bibliografía	116
6.	Razonamiento Semántico	119
6.1.	Introducción	120
6.2.	Modelado semántico: razonamiento e inferencia	121
6.3.	Web Semántica	123
6.3.1.	Estructura de la Web Semántica	123
6.3.2.	Modelo Constructivo de La Web Semántica	124
6.3.3.	Aplicación de la Web Semántica	126
6.3.4.	Repositorios Digitales	127

6.3.5.	Utilización de Ontologías en los repositorios digitales	129
6.3.6.	Conceptos básicos de ontologías y repositorios	130
6.4.	Principales Desarrollos en México	135
6.4.1.	Academia	135
	Bibliografía	138
7.	Ciencia y Analítica de Datos	145
7.1.	Introducción	145
7.2.	La minería de datos como disciplina científica	148
7.3.	De la generación de un modelo a su aplicación	154
7.4.	Las herramientas de la analítica de datos	157
7.5.	Principios de modelación	159
7.5.1.	Modelación paramétrica	162
7.6.	Conclusión	166
	Bibliografía	167
8.	Tendencias en IA y Retos de la TD	171
8.1.	Introducción	171
8.2.	El Impacto de la IA en el 2030	173
8.2.1.	Transporte	173
8.2.2.	Robots de servicio	174
8.2.3.	Servicios de salud	176
8.2.4.	Educación	176
8.2.5.	Entretenimiento	177
8.2.6.	Negocios: Estrategias Empresariales para TD y la IA .	178
8.3.	Empleo y lugares de trabajo	180
8.4.	IA en la TD de las Organizaciones	181

ÍNDICE GENERAL

xv

8.5. Adopción de la IA en las Organizaciones	183
8.6. Tendencias en IA y Retos de la TD en México	184
8.7. Conclusión	185
Bibliografía	187

Capítulo I

Introducción

Francisco J. Cantú Ortiz

Instituto Tecnológico y de Estudios Superiores de Monterrey

La necesidad para automatizar cálculos aritméticos que rebasaban las capacidades humanas dio origen a la búsqueda de soluciones que eventualmente llevaron a la invención de la computadora digital y de las tecnologías computacionales. En un principio, dentro de las ciencias exactas y de la ingeniería, las computadoras se utilizaban para resolver sistemas de ecuaciones de grandes dimensiones por medio de métodos numéricos y aproximaciones a las soluciones exactas de las ecuaciones. Sin embargo, muy pronto se hizo claro que esta tecnología era también útil para representar el conocimiento y razonar de forma automatizada en la solución de diversos tipos de problemas. Estos descubrimientos llevaron al establecimiento de la Inteligencia Artificial (IA) como una disciplina académica en la década de los 50s gracias principalmente a las ideas de Alan Turing descritas en su influyente artículo “*Computing Machinery and Intelligence*” en donde propone el conocido “*The Imitation Game*” como una prueba para determinar si una computadora es inteligente o no lo es [1]. En este artículo se propuso también un programa de investigación para la IA junto con dos tareas principales para llevarlo a

cabo: crear máquinas capaces de jugar ajedrez, es decir de razonar, y máquinas capaces de comunicarse con los seres humanos en el lenguaje natural, para lo cual es necesario que entiendan, es decir que tengan la capacidad de representar, razonar, y expresar conocimiento.

1.1. Establecimiento de la IA y el Enfoque Simbólico

En la década de los 50 surge la primera generación de pioneros que contribuyeron al establecimiento de la IA como campo de investigación, entre los que se encuentran John McCarthy y Marvin Minsky, quienes acuñan el término Inteligencia Artificial en la conferencia de Dartmouth en 1956 e integran un grupo en el cual también se integran Herbert Simon, Alan Newell, y otros invitados [5]. Minsky se instala en el *Massachusetts Institute of Technology*, McCarthy emigra a la costa oeste y se incorpora a *Stanford University*, y Newell y Simon se establecen en *Carnegie-Mellon University* desde donde lanzan distintos programas académicos y enfoques filosóficos para abordar los retos planteados por la Inteligencia Artificial y se hacen pronósticos, en algunos casos muy optimistas sobre el tiempo que tomaría tener computadoras con capacidades equivalentes a la inteligencia humana. Algunas estimaciones indicaban que éste tiempo sería de unos 10 años, quedando muy cortos en su cumplimiento, en parte, debido a una subestimación de la complejidad inherente a los problemas relacionados con la inteligencia humana, el conocimiento y el razonamiento. Sin embargo, en los últimos 50 años la IA ha tenido primaveras e inviernos, éxitos y fracasos, así como diversos altibajos, haciendo increíbles aportaciones, y nuevas promesas y predicciones sobre las capacidades de las máquinas sobre la inteligencia humana, muchas de las cuales todavía no se han cumplido. Pero a partir de la primera década del 2000, las tecnologías de la IA en la solución de problemas en dominios específicos, han sobrepasado por mucho las capacidades humanas. Estas incluyen problemas tales como reconocimiento de voz y de imágenes en

los teléfonos celulares, algoritmos de planeación y búsqueda en juegos de ajedrez y Go, lenguaje natural en competencias de conocimientos con seres humanos, por mencionar solo algunas de ellas. Por ejemplo, en 1997 la computadora *Deep Blue* venció al campeón mundial de ajedrez, Gary Kasparov, en 2016 el profesional Surcoreano de Go, Lee Sedol, fue vencido en la competencia *DeepMind Challenge* por la computadora *AlphaGo* diseñada por Google, y hoy en día, muchos teléfonos celulares han llevado la capacidad de conversación en lenguaje natural a la sociedad en general. Aún así, esto se debe tomar con cautela ya que la comprensión profunda del lenguaje es una tarea que está todavía lejos de resolverse plenamente. En todas las tecnologías de IA podemos encontrar dos elementos que son comunes a todas ellas: el empleo de conocimiento y la utilización de métodos de razonamiento e inferencia para resolver problemas reales en diversos dominios de aplicación. Desde luego, los términos “conocimiento” y “razonamiento” evocan en principio una actividad mental humana y el término Inteligencia Artificial ha tenido sus detractores; sin embargo, es un hecho que las máquinas del siglo 21 tienen la capacidad de representar conocimiento y razonar, por ejemplo, para hacer diagnósticos, tomar decisiones y planear en una gran variedad de entornos y aplicaciones reales, utilizando diversos enfoques de la IA, aunque en este libro, consideraremos principalmente el enfoque simbólico propuesto por Newell y Simon, y las tecnologías asociadas a este enfoque, como se explica en la siguiente sección.

1.2. Tecnologías de Inteligencia Artificial

En esta sección describimos las principales tecnologías empleadas en Inteligencia Artificial para diseñar y poner en operación software y máquinas inteligentes capaces de interactuar de manera inteligible con seres humanos así como con el medio ambiente y el contexto en el cual se desempeñan. No tocaremos todas las tecnologías de IA actualmente en uso (eso se describe en otros libros editados por la Academia Mexicana de la Computación,) sino solo aquellas que siguen primordialmente el enfoque simbóli-

co basado en lógica matemática junto con probabilidad y estadística. Este enfoque fue propuesto por *Newell* y *Simon* a través de la Hipótesis de los Símbolos Físicos que esencialmente establece que un sistema de símbolos operados por una máquina que sigue el modelo de la Máquina de Turing, tiene los medios necesarios para producir comportamiento inteligente general [10]. Es solo una hipótesis más que un teorema que ya haya sido demostrado, y sólo se podrá verificar su validez o su invalidez de manera experimental, pero hasta el momento, no hay evidencias que muestren que la hipótesis sea inválida. De esta hipótesis se derivan varios enfoques de la IA entre los que destacan el enfoque basado en lógica (los *Neats*) y el enfoque conexionista (los *Scruffies*), además del enfoque evolucionista propuesto por John Holland en 1975 [2]. El enfoque conexionista dio origen a las Redes Neuronales ampliamente utilizadas en reconocimiento de voz, procesamiento de imágenes y en algoritmos de Aprendizaje Profundo (o *Deep Learning*). El enfoque evolucionista se construye inspirándose en el paradigma de la evolución de las especies el cual es simulado a través de algoritmos genéticos y evolutivos. En este libro nos enfocaremos solamente en el enfoque basado en Lógica Matemática como medio esencial para representar el conocimiento, razonar con él, y realizar inferencias con premisas y conclusiones representadas mediante formalismos lógicos. Los esquemas de lógica matemática a considerar incluyen la lógica proposicional y la lógica de predicados de primer orden, incluyendo lógicas descriptivas, estas últimas ampliamente utilizadas en esquemas de representación del conocimiento mediante ontologías y anotaciones semánticas. Esto incluyendo el tratamiento de la incertidumbre y el razonamiento con información incompleta o incierta, el razonamiento causal, el descubrimiento de conocimiento oculto en grandes volúmenes de datos, y paquetes de software encapsulados en la forma de agentes autónomos inteligentes, y redes de estos agentes autónomos llamados sistemas multiagente.

1.2.1. Razonamiento Lógico

El razonamiento deductivo tiene sus orígenes en la Grecia antigua con el trabajo de Aristóteles quien descubrió y propuso los silogismos como una manera organizada y sistemática para realizar razonamientos válidos y libres de errores o falacias. Estos esquemas de razonamiento permanecieron vigentes por casi dos mil años, hasta que fueron validados y generalizados a partir del siglo XIX con las investigaciones de George Boole, Augusto De Morgan, Gottlob Frege, Georg Cantor, Giuseppe Peano, y en el siglo 20 por matemáticos como Bertrand Russell, David Gilbert, Alfred Tarski, Kurt Godel, y Alan Turing. El paradigma de lógica de mayor influencia en las tecnologías digitales es sin duda la lógica proposicional conocida también como lógica Booleana, que proporciona los fundamentos matemáticos para el diseño de compuertas y circuitos lógicos digitales basados en álgebra Booleana para modelar las operaciones lógicas. La lógica de primer orden conocido también como lógica o cálculo de predicados fue sistematizada a fines del siglo XIX por los trabajos de Gottlob Frege y Charles Sanders Peirce. En los 60's, Alan Robinson propone la regla de inferencia basada en Resolución para llevar a cabo deducciones lógicas [9]. Robert Kowalski desarrolla en Edinburg refinamientos al esquema básico de resolución como la Resolución SLR, que sientan las bases para el surgimiento de la Programación Lógica. Prolog, qué significa Programación en Lógica, es un lenguaje de programación desarrollado en Francia por Alain Colmerauer en colaboración con el Inglés Robert Kowalski. Prolog trabaja con un subconjunto de lógica de primer orden conocido como cláusulas de Horn propuestas a su vez por Alfred Horn en 1951. El problema de encontrar valores de verdad para hacer que una conjunción de cláusulas de Horn sea verdadera es un problema P-Completo Un problema P-Completo es un problema de decisión que puede ser resuelto eficientemente usando computadoras paralelas. que se puede resolver en tiempo lineal, aunque el problema de satisfacibilidad de una cláusula de Horn de primer orden es un problema indecidible. El lenguaje Prolog despertó amplias expectativas para la construcción de máquinas inteligentes que inspiró al programa de computadoras de la 5ª generación concebida por Japón en la década de los 80. Las promesas y expectativas generadas por este programa no fueron cumplidas. Otros usos y aplicaciones de la programación lógica incluyen la programación lógica con restricciones, la programación lógica abductiva, y el cálculo de eventos desarrollados por Robert Kowalski. John McCarthy y Patrick Hayes plantea-

ron el llamado *Frame Problem* al usar lógica de primer orden para expresar hechos del mundo real en el modelo que un robot usa para interactuar su medio ambiente. El problema consiste en que al representar cambios en el medio ambiente, surge la necesidad de agregar una gran cantidad de hechos para representar las cosas que no cambian y que permanecen igual. Hasta la fecha, este problema se sigue investigando, y para dar respuesta a estos planteamiento se iniciaron investigaciones en otro tipo de lógicas como las lógicas de orden superior. La ventaja de las lógicas de orden superior es principalmente su expresividad y facilidad para representar estructuras complejas de conocimiento y lenguajes. Pero esto tiene un costo, que es la complejidad exponencial generada en tiempo y espacio por los algoritmos de búsqueda y razonamiento que se hace sobre estas estructuras. Una lógica de segundo orden es una extensión de una lógica de primer orden en la que se añaden variables que representan conjuntos, funciones y relaciones, y cuantificadores que operan sobre esas variables. Con esto se incrementa el poder expresivo del lenguaje sin tener que agregar nuevos símbolos lógicos. Un tipo de lógicas de orden superior son las lógicas descriptivas utilizadas en el razonamiento semántico sobre ontologías Web, como se describe en la siguiente sección.

1.2.2. Razonamiento Semántico

El razonamiento semántico se da en el contexto de los contenidos de la *World Wide Web* (WWW) que es lanzada y es operada por el *World Wide Web Consortium* (W3C) liderado por Sir Tim Berners-Lee, autor de esta misma. La WWW se creó con el objetivo de conectar personas para intercambiar y/o consumir datos. Posteriormente, estas personas podían también producir datos. Ejemplos de esto son las redes sociales o sitios tipo Wiki. Esa gran cantidad de datos producidos carecían de significado semántico para poder ser usados en algún tipo de razonamiento o inferencia. De ahí el surgimiento de la Web Semántica. El objetivo de esta es desarrollar tecnologías para publicar datos útiles a aplicaciones computacionales, y se basa en la idea de añadir metadatos semánticos y ontológicos a sitios en la WWW que describen el contenido, el significado y la relación entre los datos. De esta manera, la información contiene datos especiales (llamados metadatos) que describen su significado en un cierto contexto (llamado ontología) además de las conexiones con otros datos. Un requerimiento es que los datos y sus metadatos se deben proporcionar por parte de los usuarios para poder procesarlos y realizar razonamientos semánticos sobre ellas. Este modelo permite incorporar contenido semántico a toda la información

generada en la WWW generando una mejor organización de la información y asegurando búsquedas más precisas por significado y no por contenido textual. Finalmente, esto permite a las computadoras la gestión de conocimiento que hasta el momento esta reservada a las personas. Usando esta representación de conocimiento es posible usar cualquier dato publicado por un servicio web (redes sociales, páginas web, etc) como entrada para algún proceso automatizado o algoritmo que permita generar inferencias o razonamiento.

1.2.3. Razonamiento Probabilístico y Modelos Causales

Los problemas del mundo real se dan en ambientes de incertidumbre, información incompleta, o información inconsistente. Tradicionalmente se ha utilizado la probabilidad y la estadística como mecanismo para manejar la incertidumbre, poder interpretar eventos pasados y hacer pronóstico sobre comportamiento de eventos futuros. En los 80's se propusieron modelos de manejo de incertidumbre como alternativa a la complejidad de tipo exponencial producida al emplear distribuciones de probabilidad multivariable, como fue el caso de los factores de certeza, pero se demostró que estos modelos resultaron ser inconsistentes. La introducción de redes Bayesianas por Judea Pearl a fines de los 80 como un mecanismo para acortar el espacio de búsqueda generado por las distribuciones de probabilidad multivariable proporcionó la herramienta que era requerida para manejar adecuadamente la incertidumbre en sistemas basados en el conocimiento al estar construido sobre las bases axiomáticas de la teoría de probabilidad [6]. Desde entonces, las redes Bayesianas de diversos tipos se han perfeccionado para hacer frente a los problemas de incertidumbre en aplicaciones reales. Pearl también abordó el tema de la causalidad entendida como la relación entre un evento y el efecto ocasionado. Las relaciones se pueden dar entre acontecimientos, procesos, fenómenos naturales, psicológicos o sociales. Se dice que algo es causa de un efecto cuando este último depende del primero, es decir, la causa es aquello que hace que el efecto sea lo que es. Existen dos condiciones necesarias pero no suficientes para que A sea causa de B, estas son, que A se anterior a B en el tiempo, y que A y B estén relativamente cercanos en el espacio y en el tiempo. Aristóteles distinguió cuatro tipos de causas asociadas a la explicación del ser, que son la causa material, la causa formal, la causa eficiente y la causa final. Esta concepción de la causalidad fue criticada por el filósofo Inglés David Hume y replanteada por el filósofo Alemán por Emmanuel Kant. Pearl definió un modelo matemático de la causalidad utilizado en ciencias empíricas que ha sido ampliamente aceptado, construyendo sobre

su trabajo con redes Bayesianas [7]. Otra alternativa al manejo de la incertidumbre es el modelo propuesto por Lotfi Zadeh, autor de la lógica difusa o Fuzzy Logic en la década de los 60s, utilizada actualmente en sistemas de control y robótica [13].

1.2.4. Razonamiento Estadístico

La estadística es la ciencia de obtener información a partir de los datos. En ese sentido un dato es una observación o medición, expresada en un número. Una estadística puede referirse a un determinado valor numérico derivado de los datos. Esta área ha sido fundamental en la representación de conocimiento para posteriormente razonar sobre ella. En ese sentido este proceso se puede dividir en tres pasos: (1) recopilar los datos, (2) analizarlos y (3) obtener inferencias a partir de los mismos. Esta área usa una representación de datos diferentes a las descritas anteriormente, usualmente son datos de observaciones que son almacenados en estructuras de datos tipo tabla. Esta área es la base lo que conocemos como minería de datos o ciencia de datos, en donde las representaciones de datos no sólo son estructurada (tipo tabla) si no también no estructuradas.

1.2.5. Ciencia y Analítica de Datos

El crecimiento en las capacidades de almacenamiento de datos en dispositivos digitales así como nuevas tecnologías de sensores y mejores anchos de banda en la transmisión de datos han permitido el almacenamiento de grandes cantidad de datos como resultado de las operaciones diarias de los negocios, los hogares, las ciudades, y en la vida cotidiana en general. Esto ha permitido el establecimiento de la minería de datos o *Knowledge Discovery in Databases* (KDD), como una disciplina que utiliza la estadística y las tecnologías de IA para descubrir patrones en grandes conjuntos de datos. Los métodos utilizados incluyen aprendizaje automático, la estadística y los sistemas de bases de datos. El objetivo es extraer información escondida en los datos y transformarla en información y conocimiento útil para la toma de decisiones. Incluye también aspectos de gestión de datos y de bases de datos, de procesamiento de datos, del modelo y de las consideraciones de inferencia, de métricas, teoría de la complejidad computacional, evaluación de la información descubierta, y la visualización de la información [3]. Los pasos asociados a un proceso de minería de datos son los siguientes: (1) Selección del conjunto de datos, tanto

en lo que se refiere a las variables objetivo sobre las cuales se hará una predicción, como a las variables independientes que son las que sirven para hacer la predicción, incluyendo la muestra de datos. (2) Análisis de las propiedades de los datos para llevar a cabo una curación o limpieza de los mismos, datos atípicos, así como datos faltantes o incompletos. (3) Transformación de los datos de entrada para aplicar la técnica de minería de datos más apropiada a los datos y al problema. (4) Escoger y aplicar la técnica de minería de datos para construir el modelo predictivo, de clasificación o de segmentación, dependiendo del objetivo del proyecto. (5) Extracción de conocimiento e información útil, mediante la técnica de minería de datos seleccionada. Se pueden aplicar varias técnicas para generar distintos modelos, aunque generalmente cada técnica obliga a un proceso de preparación de datos diferente. (6) La interpretación de la información extraída y el conocimiento nuevo generado, y finalmente, (7) La evaluación de la utilidad del conocimiento aplicado y del proceso de minería de datos completo [8].

1.2.6. Sistemas Multiagente

Un Sistema Multiagente (SMA) se compone de un conjunto de agentes autónomos con capacidad para interactuar con el medio ambiente, representar la información recibida en bases de conocimiento, y razonar con esta información para generar conocimiento, aprender, comunicarse con otros agentes, y emitir recomendaciones a otros agentes autónomos o agentes humanos. Los sistemas multiagente se utilizan para resolver problemas en forma coordinada, lo cuál no sería posible para un solo agente en dominios tales como comercio electrónico mediante el modelado de instituciones electrónicas, situaciones de desastre, problemas sociales, y en general cualquier problema en el que se requiera trabajo en equipo para encontrar una solución [12].

1.3. Investigación en México

La comunidad de Inteligencia Artificial en México ha sido una de las agrupaciones académicas mejor organizadas en el país. Esto se refleja en el número de investigadores activos en el área, la cantidad de grupos de investigación en instituciones académicas, el número de estudiantes realizando estudios en el extranjero, las conferencias organizadas por entidades nacionales, los programas académicos de posgrado de IA en el país, las aplicaciones industriales de la IA, y la actividad de la Sociedad Mexicana de Inteligencia Artificial, como impulsora del desarrollo de

la IA. La Inteligencia Artificial en México se remonta a los trabajos realizados desde los 40's por el fisiólogo e investigador Mexicano Arturo Rosenblueth en el área de la Cibernética, en colaboración con Norbert Wiener y Julian Bigelow. Wiener y Rosenblueth idearon un instituto interdisciplinario de científicos independientes quienes trabajarían juntos en temas de interés, como colegas, no subordinados a una oficina ejecutiva, y ayudándose mutuamente. Wiener y Rosenblueth estaban interesados entre otras cosas en las analógicas que pudieran encontrarse entre dispositivos electrónicos y sistemas biológicos. Sin embargo, el surgimiento de la segunda guerra mundial pospuso sus planes. Wiener y Bigelow, involucrándose en proyectos de defensa, iniciaron el estudio de la retroalimentación en servomecanismos, y contactaron a Rosenblueth para que los asesorara en los problemas de retroalimentación excesiva en el cuerpo humano, desarrollando un modelo del sistema nervioso central que podía explicar algunas de sus actividades más características en términos de procesos circulares, emergentes del sistema nervioso y dirigidos hacia los músculos, para entrar de nuevo en el sistema nervioso a través de órganos sensores. Este modelo fue publicado en 1943 en el artículo seminal "*Behavior, Purpose and Teleology*" en la revista *Philosophy of Science*. Este proponía una manera de enmarcar el concepto de "propósito" establecía la definición de un programa de investigación experimental y multidisciplinario. De aquí surgió el estudio sistemático de problemas de comunicación, control, y mecánica estadística en máquinas o animales, acuñando el término Cibernética, cuya etimología proviene de la palabra griega para piloto ó timonel. Durante los 50's se instalan las primeras computadoras digitales en México en la UNAM y en las empresas de Monterrey. Durante los 60's crece el número de computadoras en México y se establecen los primeros programas académicos en Computación en el país en el Tecnológico de Monterrey y el Instituto Politécnico Nacional (IPN). Durante los 60's y los 70's varios jóvenes Mexicanos viajan al extranjero a realizar estudios de posgrado y al regresar se incorporan a distintas universidades del país para iniciar estudios de IA. Entre estos sobresale Adolfo Guzmán Arenas quien estudió en el MIT bajo la dirección de Marvin Minsky, uno de los fundadores de la IA. En los 80's, se establece la Sociedad Mexicana de Inteligencia Artificial (SMIA), específicamente en 1983, para formalizar e impulsar la actividad de investigación en la disciplina. El promotor, fundador y primer presidente fue José Negrete Martínez durante el periodo (1986-1989) seguido por Pablo Noriega, (1990-1991), Antonio Sánchez Aguilar (1992-1993), Christian Lemaitre (1994-1995), Ofelia Cervantes (1996-1997), Francisco Javier Cantú (1998-2000), y Enrique Sucar (2000-2002). Desde entonces, el presidente de la SMIA se elige cada dos años. Las principales conferencias en IA fueron la Reunión Nacional de IA

(RNIA) organizada por la SMIA, y el Simposium Internacional de IA (ISAI) organizado por el Tecnológico de Monterrey, que en el 2000 se integran en una sola conferencia conocida como la *Mexican International Conference on Artificial Intelligence* (MICAI) que se realiza anualmente desde el año 2000 en diferentes ciudades del país [1]. En el 2003 se lleva a cabo en el Centro de Convenciones de Acapulco la *International Joint Conference on Artificial Intelligence* (IJ-CAI), la cual es conferencia la conferencia de IA más importante del mundo. La investigación en Inteligencia Artificial que se lleva a cabo en México sigue las tendencias de la investigación a nivel mundial, y desde luego puede ser clasificada siguiendo los mismos lineamientos utilizados internacionalmente [4]. Así, los formatos de representación pueden ser proposicionales, estructurados, probabilísticos o conexionistas, mientras que las formas de inferencia pueden ser de naturaleza deductiva, abductiva o inductiva. Asimismo, los sistemas pueden ser centralizados o multiagentes, y los sistemas de conocimiento se pueden concebir como autónomos y causales de la conducta de agentes computacionales, como los robots, o pueden concebirse como servicios para apoyar la representación y el razonamiento humano. En otra dimensión, los sistemas pueden adquirir conocimiento a través de la interacción con seres humanos, aprender nuevo conocimiento mediante la inducción de aprendizaje, o utilizar grandes repositorios como las ontologías disponibles en Internet. Concluimos el primer capítulo del libro invitando al lector a leer los capítulos subsecuentes para tener un panorama más completo de los temas que se han esbozado en las secciones precedentes.

Bibliografía

- [1] Francisco J. Cantu-Ortiz. Advancing artificial intelligence research and dissemination through conference series: Benchmark, scientific impact and the micai experience. *Expert Systems with Applications*, 41(3):781–785, 2014.
- [2] John Holland. *Adaptation in Natural and Artificial Systems*. MIT Press, 1975.
- [3] Oded Maimon and Lior Rokach. *Data mining and knowledge discovery handbook*. Springer, 2010.
- [4] Emma Martinho-Truswell; H. Miller; I.N. Asare; A. Petheram; R. Stirling; C. Gómez Mont; C. Martinez. Towards an ai strategy in mexico: Harnessing the ai revolution. 2018.

- [5] John McCarthy, Marvin Minsky, Claude Elwood Shannon, and Nathaniel Rochester. *A proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. 1955.
- [6] Judea Pearl. *Probabilistic Reasoning in Intelligent Systems*. Morgan-Kaufmann, 1988.
- [7] Judea Pearl. *Causality: models, reasoning, and inference*. Cambridge University Press, 2000.
- [8] Foster Provost and Tom Fawcett. *Data science for business: what you need to know about data mining and data-analytic thinking*. OReilly, 2013.
- [9] J. A. Robinson. A machine-oriented logic based on the resolution principle. *Journal of the ACM*, 12(1):23–41, Jan 1965. doi: 10.1145/321250.321253.
- [10] Allen Newell; Herbert Simon. Computer science as empirical inquiry: Symbols and search. *Communications of the ACM*, 19(3):113–126, 1976. doi: 10.1145/360018.360022.
- [11] Alan M. Turing. Computing machinery and intelligence. *Mind*, LIX(236):433–460, Jan 1950. doi: 10.1093/mind/lix.236.433.
- [12] Gerhard Weiss. *Multiagent systems: a modern approach to distributed artificial intelligence*. MIT Press, 1999.
- [13] Lotfi Zadeh. Fuzzy logic and approximate reasoning. *Synthese*, page 407–428, 1975. doi: 10.1007/3-540-27335-2_3.

Capítulo 2

Lógica Proposicional y de Predicados

Guillermo De Ita Luna

Benemérita Universidad Autónoma de Puebla

José Raymundo Marcial-Romero

Universidad Autónoma del Estado de México

José Antonio Hernández Servín

Universidad Autónoma del Estado de México

Pedro Bello López

Benemérita Universidad Autónoma de Puebla

2.1. Introducción

La lógica proposicional se basa en el uso de oraciones que afirman o niegan algo y que por lo tanto, pueden ser verdaderas o falsas, a lo que se denomina proposiciones. La lógica proposicional de acuerdo a Pons et al. [61] se utiliza para analizar razonamien-

tos formalmente válidos, partiendo de proposiciones y operadores lógicos para poder construir fórmulas que están operando sobre las variables proposicionales.

La lógica predicativa, lógica de predicados o cálculo de predicados, es un sistema formal diseñado para estudiar la inferencia en los lenguajes de primer orden. Creignou et al. [10] presentan un ejemplo aplicado a la revisión de creencias, donde los modelos de fórmulas son cerrados bajo funciones Booleanas.

Por otro lado, los lenguajes de primer orden son, a su vez, lenguajes formales con cuantificadores cuyo ámbito alcanza sólo a variables y con predicados y funciones cuyos argumentos son sólo constantes o variables, la lógica de primer orden tiene un poder expresivo superior al de la lógica proposicional.

Uno de los objetivos de la lógica proposicional o de predicados en las ciencias de la computación es el desarrollo de lenguajes para modelar tanto las situaciones, los problemas y los algoritmos que los resuelven, y de tal forma, que se pueda razonar de manera formal sobre los modelos propuestos. Razonar sobre las situaciones significa la construcción de argumentos acerca de éstos, de forma que los argumentos sean válidos y puedan ser defendidos de forma rigurosa, o ejecutados de forma automática en una computadora.

La mayoría de las veces, cuando se usa una lógica para el diseño, especificación y verificación de sistemas computacionales se plantea la relación: $\mathcal{M} \models \phi$, que significa determinar si la fórmula ϕ se implica lógicamente de \mathcal{M} , donde \mathcal{M} es la situación o el conocimiento actual sobre una situación, y ϕ es una fórmula lógica que codifica la información que deseamos saber si es verdadera bajo la suposición \mathcal{M} , o que ϕ es satisfactible en \mathcal{M} .

Desde el punto de vista computacional se pueden diseñar e implementar algoritmos para calcular el operador de implicación lógica o de razonamiento (\models). La implicación proposicional de acuerdo a Cresto [11] es una tarea importante en problemas tales como la estimación del grado de creencia y actualización de las creencias, en el trabajo con procedimientos y en las aplicaciones de la Inteligencia Artificial. Por ejemplo, cuando

se trabaja en la planificación y diseño de sistemas multiagente, en el diagnóstico lógico, el razonamiento aproximado y en el conteo del número de soluciones para instancia de satisfactibilidad, como se indica en Doubois [18], entre otras aplicaciones.

En general, el problema de la implicación lógica es un reto para el razonamiento automático, ya que se conoce que es un problema en la clase Co-NP completo, incluso en el caso proposicional, como lo muestran Khardon et al. [44] y Liberatore [49]. En el desarrollo de algoritmos que resuelvan de forma automática el problema de implicación lógica, se utilizan algoritmos originalmente diseñados para resolver un problema relacionado: el problema de Satisfactibilidad (SAT).

En este capítulo se abordan algunos problemas que se plantean al resolver el problema de implicación lógica acotada al cálculo proposicional: **Satisfactibilidad (SAT)**, **Satisfactibilidad incremental (ISAT)**, **Transición de fase y Revisión de creencias**. Estos temas han sido elegidos para su estudio ya que presentan extensiones naturales al problema de analizar la consistencia de la información en ambientes dinámicos, esto es, mientras se contrae o se extiende una base inicial de información o una base de conocimiento.

2.1.1. Conceptos básicos

En la lógica proposicional [24], a los símbolos \wedge , \vee y \neg se le llama *conectivas lógicas*. Los conectores \wedge y \vee denotan conjunción (*y*) y disyunción (*o*) respectivamente de dos proposiciones mientras que \neg es el operador de negación. También se pueden construir conectivos derivados como \rightarrow o \Leftrightarrow a partir de las conectivas anteriores.

Las proposiciones en la lógica proposicional por lo general se denotan con variables booleanas es decir que pueden ser verdaderas o falsas. Sea $X = \{x_1, \dots, x_n\}$ un conjunto de n variables booleanas. Una **literal** denotada como *lit*, es una variable x_i o la negación de la variable $\neg x_i$. Una **cláusula** es una disyunción de diferentes literales. Para $k \in \mathbb{N}$, k -cláusula es un cláusula con exactamente k literales, en general una cláusula es un conjunto de literales. Mientras que una **frase** es una conjunción de literales. Una k -frase es

una frase con exactamente k literales. Una variable $x \in X$ aparece en una cláusula C (o frase) si x o $\neg x$ es un elemento de C .

Una **forma normal conjuntiva** (FNC) es una conjunción de cláusulas, y k -FNC es una FNC que contiene k -cláusulas. Una forma normal disyuntiva (FND) es una disyunción de frases, y k -FND es una FND que contiene k -frases.

Consideraremos aquí que una fórmula proposicional es una FNC dado la siguiente proposición.

Toda fórmula proposicional es lógicamente equivalente a una FNC, y de hecho la FNC equivalente es algorítmicamente calculable [28].

Una **asignación** s para una fórmula F es un mapeo booleano $s : \mathcal{V}(F) \rightarrow \{1, 0\}$, donde $\mathcal{V}(F)$ denota el conjunto de variables de F . Una FNC F se satisface por una asignación s si cada cláusula C se satisface por s . Un modelo F es una asignación s que satisface F .

El problema de satisfactibilidad (SAT) consiste en decidir, si dada una fórmula F , existe una asignación s que haga que F tome el valor verdadero. Toda asignación s que satisfaga a una fórmula F se dice ser un modelo para F .

2.2. Estado del arte

2.2.1. SAT y SAT incremental

SAT es uno de los problemas fundamentales en el cálculo proposicional. Determinar la satisfactibilidad de una fórmula proposicional es una tarea relevante con repercusiones en otros problemas estudiados en la Inteligencia Artificial (IA), tales como: en la estimación del grado de creencia, para revisar o actualizar las creencias [27], en la explicación abductiva, en el diagnóstico lógico y para otros procedimientos utilizados en el área de la Inteligencia Artificial.

Considerando el punto de vista semántico, el método más simple para verificar la satisfactibilidad de una fórmula F son las tablas de verdad. El método consiste en construir todas las posibles asignaciones de las proposiciones atómicas que ocurren en F para posteriormente verificar si la columna que representa F contiene al menos una valuación verdadera.

En 1960 Martin Davis y Hilary Putnam [15] desarrollaron un algoritmo para comprobar la satisfactibilidad de fórmulas de lógica proposicional en FNC. El algoritmo usa una forma de resolución en la cual las variables son elegidas iterativamente y eliminadas mediante la resolución sobre el conjunto de cláusulas de la fórmula.

En 1962 se desarrolló el algoritmo DPLL por Davis-Putnam-Logemann-Lovelandes [16], un algoritmo completo basado en el retroceso hacia atrás (backtracking) que sirve para decidir la satisfactibilidad de las fórmulas de lógica proposicional en forma normal conjuntiva; es decir, para resolver el problema SAT, al igual que lo hacía el algoritmo anterior de Davis y Putnam.

El algoritmo de Davis y Putnam se convirtió en uno de los algoritmos clásicos para decidir la Satisfactibilidad de fórmulas proposicionales y suele ser un proceso común a aplicarse en la mayoría de los algoritmos completos, como es el caso, en los algoritmos de Satz [48], SATO [69], GRASP [54] y Chaff [56].

La complejidad computacional asociada con la solución de problemas NP-completos, ha motivado la búsqueda de métodos alternativos, que permitan la solución en tiempo polinomial de instancias especiales de problemas NP-completos. Por ejemplo, en el caso del problema SAT, si F es una 2-FNC (denotado como 2-SAT), estas instancias se resuelven mediante procesos deterministas en un tiempo polinomial. Este tipo de problemas son conocidos también como problemas tratables. Las variantes de 2-SAT en las áreas de optimización y conteo han sido esenciales para establecer las fronteras entre problemas tratables e intratables en cada una de esas áreas.

A pesar de la dificultad teórica del problema SAT, los procedimientos actuales de decisión conocidos como solucionadores SAT, han sido sorprendentemente eficientes.

Estos solucionadores se han utilizado en aplicaciones industriales. En estas aplicaciones, rara vez se limita a resolver sólo un problema de satisfactibilidad, en su lugar, estas aplicaciones normalmente requieren revisar la satisfactibilidad de una secuencia de problemas relacionados. Los solucionadores modernos para SAT manejan una secuencia de problemas de satisfactibilidad como una instancia del problema de satisfactibilidad incremental (ISAT).

Las aplicaciones de SAT rara vez se limitan a resolver sólo una fórmula de entrada, una aplicación normalmente resolverá una secuencia de fórmulas relacionadas. ISAT se considera una generalización del problema SAT ya que permite cambios en el tiempo sobre la fórmula de entrada.

Hooker [39] plantea el problema de satisfactibilidad incremental. En el artículo se describe una implementación basada en el método de Davis-Putnam-Loveland para comprobar la satisfactibilidad del conjunto original de cláusulas, y considerando el caso incremental de ir adicionando nuevas cláusulas.

En general, los métodos usados en la resolución de SAT se han adaptado para resolver también ISAT, así es que tenemos métodos basados en la regla de resolución, en sistemas sintácticos, algoritmos heurísticos, y en general, en cualquiera de las técnicas diseñadas hacia la resolución de SAT.

Por ejemplo, con respecto a la clase de algoritmos heurísticos que son propuestas que intentan hallar soluciones de manera rápida (en tiempos polinomiales de cómputo), para el problema ISAT se han aplicado búsquedas locales, tales como: GSAT y WalkSAT [3], así como algoritmos evolutivos [57] y algoritmos aleatorios [34].

Mohamed [21] propone un método basado en Optimización Extrema para resolver ISAT donde también se proporcionan resultados experimentales para instancias ISAT. Los resultados obtenidos se comparan con los resultados de un algoritmo para SAT convencional.

Alban y Anbu [32] presentan un algoritmo para SAT que se extiende para ISAT y que se basa en el diagnóstico incremental de sistemas de eventos discretos. El tiempo de

ejecución de usar un algoritmo de SAT resulta ser menor que en un enfoque no incremental, los resultados obtenidos muestran tiempos de respuesta y exactitud razonables.

Por su parte, Mouhoub et al. [57] comprueban si una solución (modelo) a un problema de SAT sigue siendo un modelo cada vez que se agrega un nuevo conjunto de cláusulas y también si soluciones iniciales pueden modificarse dinámicamente y de manera eficiente para satisfacer tanto a la antigua fórmula como a las nuevas cláusulas. Se estudia la aplicabilidad de métodos sistemáticos y de aproximación para resolver ISAT.

Nadel [58] propone un método para evitar la eliminación de variables que se reintroducen en el pre-procesamiento incremental, debido a que no se puede calcular la secuencia de instancias anteriores en base solo a la dependencia entre instancias previas, también presenta una serie de experimentos con benchmarks industriales donde se muestra que la propuesta de estos autores es más rápido que varias de las alternativas conocidas.

Audemard et al. [31] dividen el espacio de búsqueda en subespacios, asignados éstos de forma sucesiva a los solucionadores de SAT que permiten la importación y exportación de cláusulas entre los solucionadores.

Anton et al. [5] presentan y prueban diferentes técnicas de pre-procesamiento que se pueden aplicar en la satisfacción Booleana (SAT), que también se relaciona con la extracción MUS (Subfórmulas Mínimamente Insatisfactibles). La propuesta permite formalizar las condiciones para la corrección en la preservación de las aplicaciones de técnicas de pre-procesamiento que no son aplicables directamente. Se evalúa experimentalmente el efecto del pre-procesamiento en relación a la extracción del grupo MUS.

Whittemore [66] presenta un método para resolver simultáneamente varias instancias SAT estrechamente relacionadas, utilizando técnicas propias de la Satisfactibilidad incremental (ISAT).

HoonSang et al. [40] presentan cómo filtrar las cláusulas de conflicto que se puedan ir transfiriendo favorablemente a instancias sucesivas, también presentan una técnica para destilar cláusulas que se reenviarán aunque falle la comprobación sintáctica.

Por su parte Wieringa [67] reduce el número de modelos en base a un enfoque semántico, lo que mejora la calidad de las cláusulas, es decir, su capacidad para evitar el examinar grandes regiones de espacio de búsqueda.

Niklas [19] muestra la modificación a un solucionador de SAT moderno, que permite resolver una serie de instancias SAT relacionadas de manera eficiente utilizando técnicas relacionadas con la verificación de modelos acotados (BMC).

Armine et al. [7] comparan enfoques de revisión de modelos acotado (BMC). Las codificaciones BMC son acotadas a un tamaño lineal para ser usadas en una lógica temporal lineal (LTL), lo que ofrece un mejor rendimiento que los enfoques alternativos basados en autómatas.

McMillan [55] propone un método SAT basado en conteo de modelo y el cálculo de interpolación como un proceso para inferir el grado de satisfactibilidad de una fórmula.

Wieringa et al. [68] investigan enfoques para paralelizar la revisión de modelos acotados (BMC) dentro de entornos de memoria compartida, así como considerando agrupamiento de estaciones de trabajo.

2.2.2. Transición de fase

Es común que las instancias de prueba para algoritmos que resuelven 3-SAT, se separen en tests-sets de instancias de prueba en casos satisfactibles y no satisfactibles [30]. En el caso de 3-SAT aleatorio, se muestra que la transición de fase entre instancias satisfactibles y no satisfactibles, se produce alrededor de $k = m/n = 4.26$ donde m es el número de cláusulas y n es el número de variables de la fórmula.

Entre las aplicaciones de SAT, esta la verificación y optimización en la automatización del diseño electrónico, para la Satisfactibilidad en circuitos combinatorios. En [45] se aplica un motor de satisfactibilidad incremental sobre una serie de aplicaciones en electrónica y automatización de diseño, realizando además el análisis de tiempo, pruebas de fallas de retardo y pruebas de fallas atascadas.

Nadel et al. [58] introducen un algoritmo para la resolución incremental de SAT bajo suposiciones, llamado última instancia Incremental (UI-SAT). UI-SAT utiliza además el sistema SatELite, y en el artículo se aplica sobre instancias con cláusulas unitarias de un conjunto disponible de 186 instancias generadas por un comprobador de modelos con límites incrementales. El algoritmo supera a los enfoques existentes sobre las instancias disponibles generadas por una aplicación industrial en la validación de hardware.

Marco et al. [6] proponen una técnica para mejorar los resultados en la realización de tareas de codificación y resolución con la revisión de modelos acotados de forma incremental (IBMC) implementado en NuSMV, el cual integra técnicas de comprobación de modelos basadas en diagrama de decisión binario (BDD). Su sistema para SAT está diseñado con una arquitectura abierta y donde se cambió el módulo codificador para realizar la codificación incremental, el módulo convertidor de una forma normal conjuntiva (FNC) se aplica para obtener el etiquetado adecuado de la fórmula procedente del codificador, y luego, el módulo decodificador puede reconstruir a partir de la tabla de símbolos y de un modelo testigo.

Otra de las aplicaciones del problema SAT es en el problema de coloreo de vértices en grafos. El coloreo de grafos consiste en colorear los vértices de un grafo con el menor número de colores posibles, de forma que 2 vértices adyacentes no pueden tener un mismo color. Si existe tal coloreo con k colores, se dice que el grafo es k -coloreable.

Prakash et al. [64] utilizan una técnica de codificación polinomial 3-SAT para el k -coloreo de un grafo, dando un enfoque de reducción del grafo 3-Colorable a la codificación 3-SAT, donde se utiliza el enfoque de restricción de vértice y el enfoque de restricción de aristas para codificar el grafo k -coloreable en expresiones 3-FNC.

2.2.3. Revisión de creencias

En lo que respecta al problema de revisión de creencias, se sabe que el paradigma más conocido para la revisión de creencias es el modelo AGM. Alchourrón et al. [1] desarrollaron un modelo para el cambio de creencias, donde la operación de revisión de

creencias privilegia a la nueva información con respecto a las creencias ya existentes en el conocimiento del agente, es necesario hacer notar que también es relevante conocer la fiabilidad de la fuente de la nueva información, tal y como lo cita Liberatore [50].

Posteriormente, Katsuno et al. [42] unificaron los diferentes enfoques de revisión de creencias semánticas, y reformularon los postulados AGM, llamándose ahora postulados KM. Además, Darwiche et al. [14] propusieron la revisión iterada de creencias, donde su propuesta establece una representación basada en los supuestos del modelo, a esto le llamaron: modelo DP. Darwiche [13] propone la aplicación de un modelo para mantener la consistencia en la revisión de creencias.

Hay algunas propuestas de revisión de creencias sobre la base de modelos y se identifican por el nombre de sus autores, Dalal, Satoh, Winslett, Borguida y Forbus como lo indica Liberatore et al. [52]. El operador descrito por Dalal [12], sugiere la revisión en base a la distancia mínima de Hamming entre interpretaciones y bases de conocimiento. En la práctica, esta propuesta consiste en el cálculo del conjunto de modelos, lo que es muy costoso computacionalmente. Uno de los inconvenientes del enfoque de Dalal está limitado en el caso de bases de conocimiento coherente.

Por lo tanto en Liu et al. [62] proponen un nuevo método de cálculo Dalal para que en el proceso de revisión se evite el cálculo de modelos de bases de creencias, sin embargo éste sólo funciona para una forma normal disyuntiva. Perrussel et al. [53] proponen una nueva distancia mínima, en lugar de la distancia de Hamming, para adoptar una creencia como un hecho.

La propuesta descrita por Satoh [63] es similar a la de Dalal, con la diferencia de que la distancia entre los dos modelos se define como el conjunto de literales diferentes entre ambos. En el caso de Winslett, la propuesta se basa en una posible comparación entre todos los máximos sistemas coherentes.

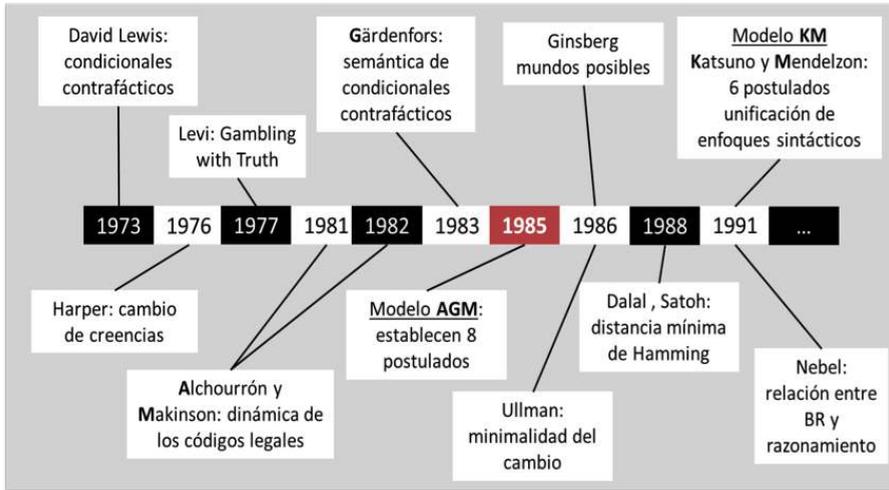


Figura 2.1: Desarrollo de la teoría de revisión de creencias 1973-1991

En la figura 2.1 se describe el desarrollo de la teoría de revisión de creencias de 1973 a 1991, la mayoría de los autores hacen referencia a los trabajos de Alchourrón et al. [1] con el modelo AGM, existen trabajos anteriores como son Lewis [65] y Harper [38] sobre condicionales contrafácticos (un condicional contrafáctico es aquel tal que $(\mathcal{A} \rightarrow B)$ cuyo antecedente (\mathcal{A}) es falso).

Levi [47] presenta un amplio debate sobre el problema de la creencia racional desarrollada sobre el modelo de teoría de la decisión bayesiana. Posteriormente Alchourron et al. [1] formalizan la dinámica de los códigos legales. Mientras que Gärdenfors [29] establece una semántica para los condicionales contrafácticos.

En el artículo Fermé, E. (2007) [27] describe que Gordenfors siendo editor de la revista *Theoria*, recibe el artículo de Alchourrón y Makinson y descubre que estaban trabajando en los mismos problemas formales, aunque desde diferentes ópticas, por lo que deciden unir esfuerzos y así surge en 1985 la propuesta del modelo que lleva sus iniciales, el modelo AGM que ha sido el origen de esta teoría de revisión de creencias [1].

Grove [33] presenta un modelo alternativo para las funciones de cambio, basado en un sistema de esferas para los “mundos posibles”, este modelo provee una semántica para el modelo AGM que permite capturar cierta noción de correctitud y completitud. Fagin et al. [22] proponen el principio de minimalidad del cambio, este principio establece que la base de conocimiento debería cambiar lo mínimo posible cuando se incorpore nueva información.

Diversos autores como Dalal, Satoh, Wislett, Borguida y Forbus propusieron métodos de revisión de creencias aplicando la distancia mínima de Hamming como muestra Dalal [12], Satoh [63] y Liberatore et al. [52]. En 1991 aparece el modelo KM por sus autores Katsuno, H. & Mendelzon, A. O. [42] que proponen la unificación de los diferentes enfoques semánticos que un operador de revisión de creencias debería cumplir a través de 6 postulados. Nebel [59] mostró una estrecha correspondencia de revisión de creencias y razonamiento.

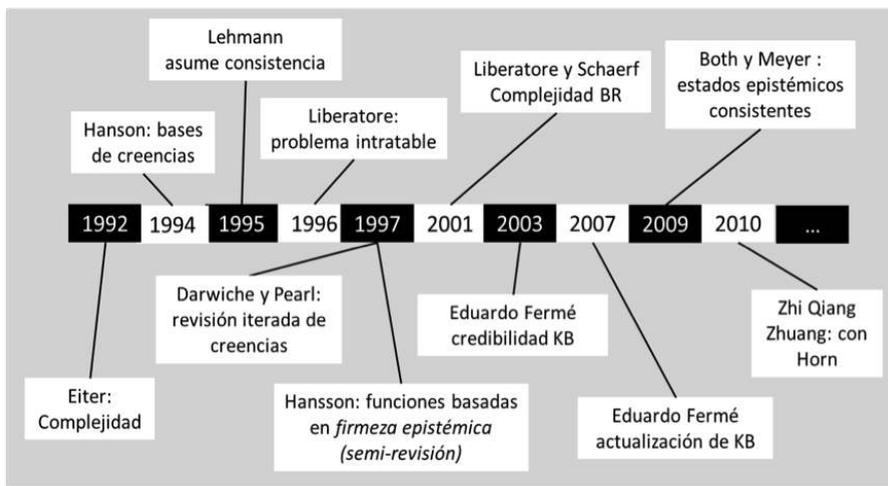


Figura 2.2: Desarrollo de la teoría de revisión de creencias 1992-2010

En la figura 2.2 se muestra el principal desarrollo de la teoría de revisión de creencias entre los años 1991-2010. Eiter et al. [20] presentan un primer análisis de la complejidad

del problema de revisión de creencias. Por su parte Fermé [27] indica que posterior a la propuesta AGM, Alchourrón y Makinson desarrollaron un modelo constructivo para funciones de cambio llamado “contracción segura” que después fue generalizada por Hansson [35] denominándola contracción del núcleo, la cual esta basada en una selección entre las sentencias de un conjunto de creencias K que contribuyen efectivamente a implicar una proposición p ; y usar esta selección para contraer K por p . Lehmann [46] propone que cada observación es una sentencia general que se asume consistente.

Eiter et al. [20] exploran la complejidad computacional de los métodos de revisión de creencias de bases de conocimiento, aunque todos los métodos que se conocen hasta ahora son intratables en el caso general es relevante encontrar bajo qué restricciones algunos métodos pudieran ser tratables [51].

En 1997 aparecieron dos modelos más, el primero denominado DP por sus autores Darwiche, A. & Pearl, J. [14], los cuales propusieron postulados para una revisión de forma iterada, donde caracterizan la revisión de creencias como un proceso que puede depender de elementos de un estado que no necesariamente son capturados por un conjunto de creencias. El segundo modelo es una aportación de Hansson [36], el cual plantea un modelo alternativo a AGM, llamado semi-revisión. Éste difiere respecto del modelo estándar en que la sentencia que provoca una revisión no siempre es aceptada.

Fermé et al. [26] proponen representar el conocimiento a través de bases de creencias en lugar de teorías lógicas y aquellos en los que el objeto del cambio epistemológico no tiene prioridad sobre la información existente como es el caso en el modelo AGM. Both et al. [2] consideraron operadores de revisión con estados epistémicos conservando consistencia. Mientras que Booth et al. [9] presentaron propuestas de revisión de creencias sobre lógica de Horn.

Fermé [27] mostró la relación entre el modelo AGM y la lógica condicional para construir funciones de cambio en la actualización de la base de conocimiento, mientras que Zhuang et al. [70] proponen la actualización de la base de conocimiento en lógica de Horn.

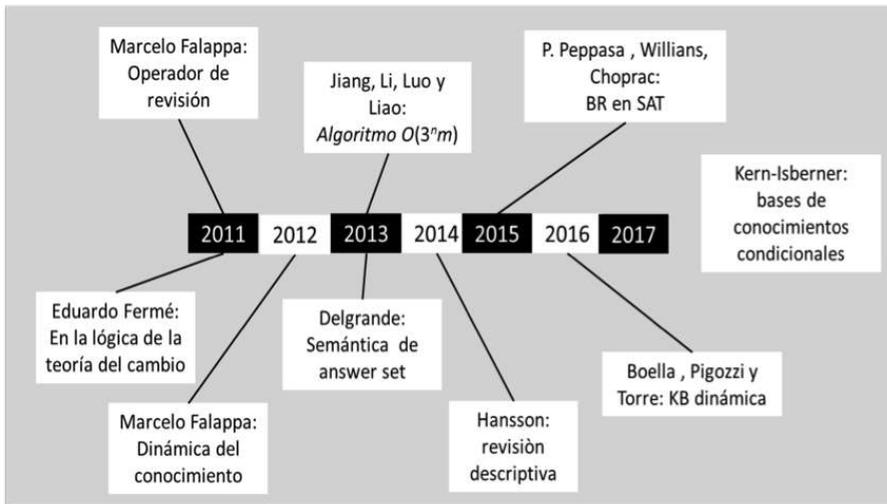


Figura 2.3: Desarrollo de la teoría de revisión de creencias 2011-2017

En el trabajo de tesis doctoral de Fermé [25] se plantea una extensión del modelo AGM en la representación del problema de revisión de creencias utilizando otros modelos como: probabilísticos, clasificación del agente de modelos que representan el grado de creencia, el lenguaje de la lógica modal, y la lógica condicional. Falapa et al. [23] proponen un operador de revisión de creencias y una descripción del desarrollo de la teoría de la dinámica del conocimiento.

Ha habido también intentos de trabajar con otro tipo de lógica como la semántica en programación lógica con el enfoque de answer-set (expresar un problema con un conjunto de reglas lógicas) por ejemplo Delgrande et al. [17].

Jiang et al. [41], presentan el análisis de la complejidad del proceso de revisión de creencias con un orden $O(3nm)$, donde n es el número de fórmulas y m es el total de literales.

Hansson [37] propone un teorema de credibilidad del enfoque AGM además del modelo más general denominado revisión descriptiva como un caso especial de la revi-

sión de creencias. Mientras que Peppasa et al. [60] reducen el problema de una operación de cambio de creencias para el problema de satisfactibilidad.

Boella et al. [8] usan entradas y salidas de teorías lógicas y revisión de creencias dinámicas con el operador de contracción de Levi.

Finalmente, Beierle et al. (2017) [4] estudian la transformación de los sistemas de bases de conocimientos condicionales, que permiten identificar y eliminar los condicionales innecesarios de la base de conocimientos y Kern-Isberner et al. [43] proponen algunos nuevos postulados para la revisión iterada múltiple que van de acuerdo a los postulados de AGM y Darwiche et al. [14].

En el diagrama de la figura 2.4 se indica en general los diferentes aspectos del proceso de revisión de creencias, se enmarca la revisión de creencias con los diferentes nombres asociados al problema y las ramas indican el nivel de aplicación del problema.

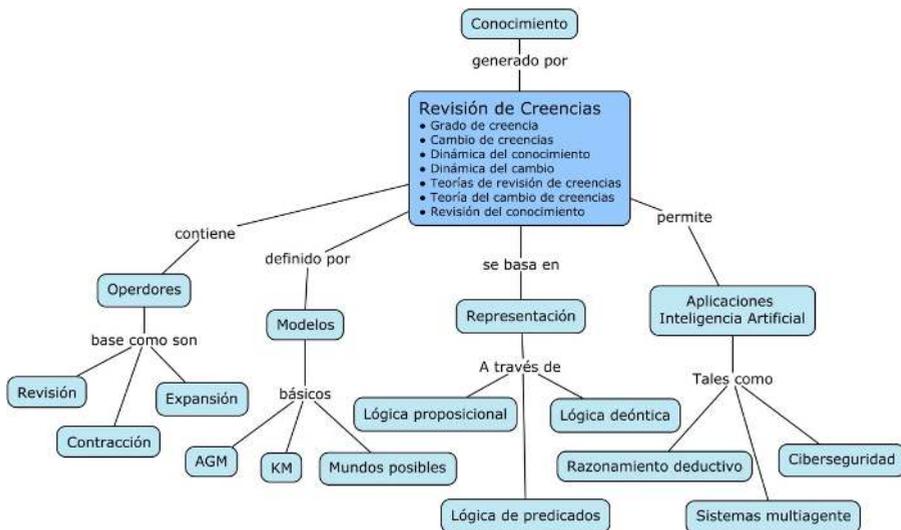


Figura 2.4: Teoría básica a considerar en la revisión de creencias

2.3. Conclusiones

En este capítulo se abordó la importancia que tienen tanto la lógica proposicional como la lógica de predicados en las ciencias computacionales, principalmente en la formalización para del proceso de razonamiento lógico. Asimismo, se explicó la importancia de la implicación lógica cuando se tiene una base de conocimiento y se quiere inferir nuevo conocimiento. En este sentido, se argumentó que el problema de satisfactibilidad (SAT), desde el punto de vista de la lógica, permite aseverar propiedades de los sistemas computacionales que abordan problemas relacionados con el razonamiento automático.

Se abordaron 4 de los problemas que tienen que ver con SAT y con su naturaleza computacional de explosión combinatoria. El enfoque de estas notas es hacia la búsqueda de algoritmos que, de forma “eficiente”, den respuestas a diferentes instancias del problema básico de Satisfactibilidad y a la revisión de creencias en el cálculo proposicional.

Se presentaron alternativas para SAT, SAT incremental, transición de fase y revisión de creencias; este último siendo de los más abordados por las repercusiones que tiene en el área de las bases de conocimiento de naturaleza dinámica. Si bien este capítulo es una breve introducción a problemas específicos de la lógica proposicional en las ciencias de la computación, consideramos que contiene referencias suficientes para que el lector se pueda adentrar en estos temas.

Bibliografía

- [1] C. Alchourron, P. Gärdenfors, and D. Makinson. On the logic of theory change: Partial meet contraction and revision functions. *Journal of Symbolic Logic*, 50: 510–530, 1985.

- [2] Meyer T. Andreas, T., K. Lee, Booth R., and J. Pan. Finding maximally satisfiable terminologies for the description logic ALC. In *Proceedings, The Twenty-First National Conference on Artificial Intelligence and the Eighteenth Innovative Applications of Artificial Intelligence Conference, July 16-20, 2006, Boston, Massachusetts, USA*, pages 269–274, 2006. URL <http://www.aaai.org/Library/AAAI/2006/aaai06-043.php>.
- [3] C. Ansótegui and F. Manyà. An introduction to satisfiability algorithms. *INTELLIGENCIA ARTIFICIAL*, 7, II 2003. doi: 10.4114/ia.v7i20.374.
- [4] C. Beierle, C. Eichhorn, and G. Kern-Isberner. On transformations and normal forms of conditional knowledge bases. In *Advances in Artificial Intelligence: From Theory to Practice - 30th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems, IEA/AIE 2017, Arras, France, June 27-30, 2017, Proceedings, Part I*, pages 488–494, 2017. doi: 10.1007/978-3-319-60042-0_53. URL https://doi.org/10.1007/978-3-319-60042-0_53.
- [5] A. Belov, M. Jarvisalo, and J. Marques-Silva. Formula preprocessing in mus extraction. In Nir Piterman and Scott A. Smolka, editors, *Tools and Algorithms for the Construction and Analysis of Systems*, pages 108–123, Berlin, Heidelberg, 2013. Springer Berlin Heidelberg. ISBN 978-3-642-36742-7.
- [6] M. Benedetti and S. Bernardini. Incremental compilation-to-sat procedures. In *Proceedings of the 7th International Conference on Theory and Applications of Satisfiability Testing, SAT'04*, pages 46–58, Berlin, Heidelberg, 2005. Springer-Verlag. ISBN 3-540-27829-X, 978-3-540-27829-0. doi: 10.1007/11527695_4. URL http://dx.doi.org/10.1007/11527695_4.

- [7] A. Biere, K. Heljanko, T. Junttila, T. Latvala, and V. Schuppan. Linear encodings of bounded LTL model checking. *CoRR*, abs/cs/0611029, 2006. URL <http://arxiv.org/abs/cs/0611029>.
- [8] G. Boella, G. Pigozzi, and L. van der Torre. AGM contraction and revision of rules. *Journal of Logic, Language and Information*, 25(3-4):273-297, 2016. doi: 10.1007/s10849-016-9244-9. URL <https://doi.org/10.1007/s10849-016-9244-9>.
- [9] R. Booth, T. Meyer, and I. Varzinczak. Next steps in propositional horn contraction. *Proc. 21st. Int. Joint the conference on artificial Intelligence - IJCAI*, pages 702-707, 2009.
- [10] N. Creignou, O. Papini, P Reinhard, and S. Woltran. Belief revision within fragments of propositional logic. In *Proceedings of the Thirteenth International Conference on Principles of Knowledge Representation and Reasoning, KR'12*, pages 126-136. AAAI Press, 2012. ISBN 978-1-57735-560-1. URL <http://dl.acm.org/citation.cfm?id=3031843.3031860>.
- [11] E. Cresto. Revisión de creencias y racionalidad. *Cuadernos CIMBAGE*, 5:133-156, 2002.
- [12] M. Dalal. Investigations into theory of knowledge base revision. *Proc. of the 7th National Conf. on Artificial Intelligence, AAAI*, (475-479), 1988.
- [13] A. Darwiche. On tractable counting of theory models and its application to truth maintenance and belief revision. *Applied Non-Classical Logics*, 11:11-34, 2001.
- [14] A. Darwiche and J. Pearl. On the logic of iterated belief revision. *Artificial Intelligence*, 89:1-29, 1997.

- [15] M. Davis and H. Putnam. A computing procedure for quantification theory. *J. ACM*, 7(3):201–215, July 1960. ISSN 0004-5411. doi: 10.1145/321033.321034. URL <http://doi.acm.org/10.1145/321033.321034>.
- [16] M. Davis, G. Logemann, and D. Loveland. A machine program for theorem-proving. *Commun. ACM*, 5(7):394–397, July 1962. ISSN 0001-0782. doi: 10.1145/368273.368557. URL <http://doi.acm.org/10.1145/368273.368557>.
- [17] J. Delgrande, P. Peppas, and S. Woltran. Agm-style belief revision of logic programs under answer set semantics. In *Logic Programming and Nonmonotonic Reasoning, 12th International Conference, LPNMR 2013, Corunna, Spain, September 15-19, 2013. Proceedings*, pages 264–276, 2013. doi: 10.1007/978-3-642-40564-8_27. URL https://doi.org/10.1007/978-3-642-40564-8_27.
- [18] O. Dubois. Counting the number of solutions for instances of satisfiability. *Theoretical Computer Science*, 81:49–64, 1991.
- [19] N. Eén and N. Sörensson. Temporal induction by incremental sat solving. *Electronic Notes in Theoretical Computer Science*, 89(4):543 – 560, 2003. ISSN 1571-0661. doi: [https://doi.org/10.1016/S1571-0661\(05\)82542-3](https://doi.org/10.1016/S1571-0661(05)82542-3). URL <http://www.sciencedirect.com/science/article/pii/S1571066105825423>. BMC’2003, First International Workshop on Bounded Model Checking.
- [20] T. Eiter and G. Gottlob. On the complexity of propositional knowledge base revision, updates, and counterfactuals. *Artif. Intell.*, 57(2-3):227–270, 1992. doi: 10.1016/0004-3702(92)90018-S. URL [https://doi.org/10.1016/0004-3702\(92\)90018-S](https://doi.org/10.1016/0004-3702(92)90018-S).
- [21] M. El-Bachir-Menaï. An evolutionary local search method for incremental satisfiability. In Bruno Buchberger and John Campbell, editors, *Artificial Intelligen-*

- ce and Symbolic Computation*, pages 143–156, Berlin, Heidelberg, 2004. Springer Berlin Heidelberg. ISBN 978-3-540-30210-0.
- [22] R. Fagin, G. Kuper, J. Ullman, and M. Vardi. Updating logical databases. *Advances in Computing Research*, 3:1–18, 1986.
- [23] M. Falappa, A. García, G. Kern-Isberner, and G. Simari. On the evolving relation between belief revision and argumentation. *Knowledge Eng. Review*, 26(1):35–43, 2011. doi: 10.1017/S0269888910000391. URL <https://doi.org/10.1017/S0269888910000391>.
- [24] R. Farré, R. Nieuwenhis, P. Nivela, A. Oliveras, E. Rodríguez, and J. Sierra. *Lógica para informáticos*. Alfaomega, México, 1 edition, 2012. ISBN 978-607-707-165-5.
- [25] E. Fermé and S. Hansson. AGM 25 years - twenty-five years of research in belief change. *J. Philosophical Logic*, 40(2):295–331, 2011. doi: 10.1007/s10992-011-9171-9. URL <https://doi.org/10.1007/s10992-011-9171-9>.
- [26] E. Fermé, J. Mikalef, and J. Taboada. Credibility-limited functions for belief bases. *J. Log. Comput.*, 13(1):99–110, 2003. doi: 10.1093/logcom/13.1.99. URL <https://doi.org/10.1093/logcom/13.1.99>.
- [27] Fermé, E. Revisión de creencias. *Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial*, 11(34):17–39, 2007.
- [28] J. Gallier. *Logic for Computer Science: Foundations of Automatic Theorem Proving*. Dover Publicatios, Philadelphia, USA, second edition, 2015.
- [29] P. Gärdenfors. Propositional logic based on the dynamics of belief. *J. Symb. Log.*, 50(2):390–394, 1985. doi: 10.2307/2274226. URL <https://doi.org/10.2307/2274226>.

- [30] I. Gent. Arc consistency in SAT. In *Proceedings of the 15th European Conference on Artificial Intelligence, ECAI'2002, Lyon, France, July 2002*, pages 121–125, 2002.
- [31] A. Gilles, H. Benoît, J. Saïd, L. Jean-Marie, and P. Cédric. Revisiting clause exchange in parallel sat solving. In Alessandro Cimatti and Roberto Sebastiani, editors, *Theory and Applications of Satisfiability Testing – SAT 2012*, pages 200–213, Berlin, Heidelberg, 2012. Springer Berlin Heidelberg. ISBN 978-3-642-31612-8.
- [32] A. Grastien and Anbulagan. Incremental diagnosis of DES by satisfiability. In M. Ghallab, C. Spyropoulos, N. Fakotakis, and N. Avouris, editors, *ECAI 2008 - 18th European Conference on Artificial Intelligence, Patras, Greece, July 21-25, 2008, Proceedings*, volume 178 of *Frontiers in Artificial Intelligence and Applications*, pages 787–788. IOS Press, 2008. ISBN 978-1-58603-891-5. doi: 10.3233/978-1-58603-891-5-787. URL <https://doi.org/10.3233/978-1-58603-891-5-787>.
- [33] A. Grove. Two modellings for theory change. *J. Philosophical Logic*, 17(2):157–170, 1988. doi: 10.1007/BF00247909. URL <https://doi.org/10.1007/BF00247909>.
- [34] D. Habiba. A monte carlo algorithm for the satisfiability problem. *Lecture Notes in Computer Science*, 1415:159–168, July 2005.
- [35] S. Hansson. Belief contraction. *Journal of Symbolic Logic*, 59:845–859, 1994.
- [36] S. Hansson. Semi-revision (invited paper). *Journal of Applied Non-Classical Logics*, 7(2), 1997.
- [37] S. Hansson. Descriptor revision. *Studia Logica*, 102(5):955–980, 2014. doi: 10.1007/s11225-013-9512-5. URL <https://doi.org/10.1007/s11225-013-9512-5>.

- [38] W. Harper. A note on universal instantiation in the stalnaker thomason conditional logic and m type modal systems. *Journal of Philosophical Logic*, 3(4): 373–379, Oct 1974. ISSN 1573-0433. doi: 10.1007/BF00257481. URL <https://doi.org/10.1007/BF00257481>.
- [39] J. Hooker. Solving the incremental satisfiability problem. *J. Log. Program.*, 15(1-2):177–186, January 1993. ISSN 0743-1066. doi: 10.1016/0743-1066(93)90018-C. URL [http://dx.doi.org/10.1016/0743-1066\(93\)90018-C](http://dx.doi.org/10.1016/0743-1066(93)90018-C).
- [40] J. HoonSang and F. Somenzi. An incremental algorithm to check satisfiability for bounded model checking. *Electron. Notes Theor. Comput. Sci.*, 119(2):51–65, March 2005. ISSN 1571-0661. doi: 10.1016/j.entcs.2004.06.062. URL <http://dx.doi.org/10.1016/j.entcs.2004.06.062>.
- [41] D. Jiang, W. Li, J. Luo, Y. Lou, and Z. Liao. A decomposition based algorithm for maximal contractions. *Frontiers Comput. Sci.*, 7(6):801–811, 2013. doi: 10.1007/s11704-013-3089-z. URL <https://doi.org/10.1007/s11704-013-3089-z>.
- [42] H. Katsuno and A. Mendelzon. On the difference between updating a knowledge base and revising it. *KR'91 Cambridge, MA, USA*, 1:387–394, 1991.
- [43] G. Kern-Isberner and D. Huvermann. Multiple iterated belief revision without independence. In *Proceedings of the Twenty-Eighth International Florida Artificial Intelligence Research Society Conference, FLAIRS 2015, Hollywood, Florida, USA, May 18-20, 2015*, pages 570–575, 2015. URL <http://www.aaai.org/ocs/index.php/FLAIRS/FLAIRS15/paper/view/10400>.
- [44] R. Khardon and D. Roth. Reasoning with models. *Artificial Intelligence*, 87: 187–213, 1996.

- [45] J. Kim, J. Whitemore, J Marques-Silva, and K. Sakallah. On applying incremental satisfiability to delay fault testing. In *Proceedings Design, Automation and Test in Europe Conference and Exhibition 2000 (Cat. No. PR00537)*, pages 380–384, March 2000. doi: 10.1109/DATE.2000.840299.
- [46] D. Lehmann. Belief revision. *Proc. IJCAI'95, IJCAI*, pages 1534–1540, 1995.
- [47] I. Levi. *Decisions and Revisions - Philosophical Essays on Knowledge and Value*. Cambridge University Press, 1984. ISBN 978-0-521-02762-5. URL <http://www.cambridge.org/uk/catalogue/catalogue.asp?isbn=9780521254571>.
- [48] C. Li and Anbulagan. Heuristics based on unit propagation for satisfiability problems. In *Proceedings of the Fifteenth International Joint Conference on Artificial Intelligence, IJCAI 97, Nagoya, Japan, August 23-29, 1997, 2 Volumes*, pages 366–371, 1997. URL <http://ijcai.org/Proceedings/97-1/Papers/057.pdf>.
- [49] P. Liberatore. The complexity of iterated belief revision. In *Proceedings of the 6th International Conference on Database Theory, ICDT '97*, pages 276–290, London, UK, UK, 1997. Springer-Verlag. ISBN 3-540-62222-5. URL <http://dl.acm.org/citation.cfm?id=645502.656098>.
- [50] P. Liberatore. Revision by history. *J. Artif. Intell. Res.*, 52:287–329, 2015. doi: 10.1613/jair.4608. URL <https://doi.org/10.1613/jair.4608>.
- [51] P. Liberatore and M. Schaerf. The complexity of model checking for belief revision and update. In *Proceedings of the Thirteenth National Conference on Artificial Intelligence and Eighth Innovative Applications of Artificial Intelligence Conference, AAAI 96, IAAI 96, Portland, Oregon, USA, August 4-8, 1996, Volume 1.*, pages 556–561, 1996. URL <http://www.aaai.org/Library/AAAI/1996/aaai96-083.php>.

- [52] P. Liberatore and M. Schaerf. Belief revision and update: Complexity of model checking. *Journal of Computer and System Sciences*, 62:43–72, 2001.
- [53] J. Marchi, G. Bittencourt, and L. Perrussel. Prime forms and minimal change in propositional belief bases. *Ann. Math. Artif. Intell.*, 59(1):1–45, 2010. doi: 10.1007/s10472-010-9206-x. URL <https://doi.org/10.1007/s10472-010-9206-x>.
- [54] J. Marques-Silva and K. Sakallah. Grasp: a search algorithm for propositional satisfiability. *IEEE Transactions on Computers*, 48(5):506–521, May 1999. ISSN 0018-9340. doi: 10.1109/12.769433.
- [55] K. McMillan. Interpolation and sat-based model checking. In Warren A. Hunt and Fabio Somenzi, editors, *Computer Aided Verification*, pages 1–13, Berlin, Heidelberg, 2003. Springer Berlin Heidelberg. ISBN 978-3-540-45069-6.
- [56] M. Moskewicz, C. Madigan, Y. Zhao, L. Zhang, and S. Malik. Chaff: Engineering an efficient sat solver. In *Proceedings of the 38th Annual Design Automation Conference, DAC '01*, pages 530–535, New York, NY, USA, 2001. ACM. ISBN 1-58113-297-2. doi: 10.1145/378239.379017. URL <http://doi.acm.org/10.1145/378239.379017>.
- [57] M. Mouhoub and S. Sadaoui. Solving incremental satisfiability. *International Journal on Artificial Intelligence Tools*, 16(1):139–147, 2007. doi: 10.1142/S0218213007003254. URL <https://doi.org/10.1142/S0218213007003254>.
- [58] A. Nadel, V. Ryvchin, and O. Strichman. Preprocessing in incremental sat. In Alessandro Cimatti and Roberto Sebastiani, editors, *Theory and Applications of Satisfiability Testing – SAT 2012*, pages 256–269, Berlin, Heidelberg, 2012. Springer Berlin Heidelberg. ISBN 978-3-642-31612-8.

- [59] B. Nebel. Belief revision and default reasoning: Syntax-based approaches. In *Proceedings of the 2nd International Conference on Principles of Knowledge Representation and Reasoning (KR'91)*. Cambridge, MA, USA, April 22-25, 1991., pages 417–428, 1991.
- [60] P. Peppas, M. Williams, S. Chopra, and N. Foo. Relevance in belief revision. *Artif. Intell.*, 229:126–138, 2015. doi: 10.1016/j.artint.2015.08.007. URL <https://doi.org/10.1016/j.artint.2015.08.007>.
- [61] C. Pons, R. Rosenfeld, and C. Smith. *Lógica para Informática*. Editorial de la Universidad Nacional de La Plata (EDULP), 2017.
- [62] P. Pozos Parra, W. Liu, and L. Perrussel. Dalal's revision without hamming distance. In *Advances in Artificial Intelligence and Its Applications - 12th Mexican International Conference on Artificial Intelligence, MICAI 2013, Mexico City, Mexico, November 24-30, 2013, Proceedings, Part I*, pages 41–53, 2013. doi: 10.1007/978-3-642-45114-0_4. URL https://doi.org/10.1007/978-3-642-45114-0_4.
- [63] K. Satoh. A probabilistic interpretation for lazy nonmonotonic reasoning. In *Proceedings of the 8th National Conference on Artificial Intelligence*. Boston, Massachusetts, USA, July 29 - August 3, 1990, 2 Volumes., pages 659–664, 1990. URL <http://www.aaai.org/Library/AAAI/1990/aaai90-099.php>.
- [64] P. Sharma and N. Chaudhari. Polynomial 3-sat encoding for k-colorability of graph. *IJCA Special Issue on Evolution in Networks and Computer Communications*, (1):19–24, 2011. Full text available.
- [65] J. Slagle and L. Norton. Experiments with an automatic theorem-prover having partial ordering inference rules. *Commun. ACM*, 16(11):682–688, 1973. doi: 10.1145/355611.362538. URL <https://doi.org/10.1145/355611.362538>.

- [66] J. Whittemore, J. Kim, and K. Sakallah. Satire: A new incremental satisfiability engine. In *Proceedings of the 38th Design Automation Conference (IEEE Cat. No.01CH37232)*, pages 542–545, June 2001. doi: 10.1145/378239.379019.
- [67] S. Wieringa. On incremental satisfiability and bounded model checking. *CEUR: Proceedings of the First International Workshop on Design and Implementation of Formal Tools and Systems*, 832:46–54, 2011.
- [68] S. Wieringa, M. Niemenmaa, and K. Heljanko. Tarmo: A framework for parallelized bounded model checking. In L. Brim and J. van-de Pol, editors, *Proceedings 8th International Workshop on Parallel and Distributed Methods in verification, PDMC 2009, Eindhoven, The Netherlands, 4th November 2009.*, volume 14 of *EPTCS*, pages 62–76, 2009. doi: 10.4204/EPTCS.14.5. URL <https://doi.org/10.4204/EPTCS.14.5>.
- [69] H. Zhang. Sato: An efficient prepositional prover. In William McCune, editor, *Automated Deduction—CADE-14*, pages 272–275, Berlin, Heidelberg, 1997. Springer Berlin Heidelberg. ISBN 978-3-540-69140-2.
- [70] Z. Zhuang and M. Pagnucco. Two methods for constructing horn contractions. In *AI 2010: Advances in Artificial Intelligence - 23rd Australasian Joint Conference, Adelaide, Australia, December 7-10, 2010. Proceedings*, pages 72–81, 2010. doi: 10.1007/978-3-642-17432-2_8. URL https://doi.org/10.1007/978-3-642-17432-2_8.

Capítulo 3

Razonamiento Probabilístico

L. Enrique Sucar

Instituto Nacional de Astrofísica, Óptica y Electrónica

Juan Manuel Ahuactzin

T-Systems México

3.1. Introducción

Muchos problemas de la vida real –diagnóstico médico, inversiones financieras, explotación petrolera– implican incertidumbre; es decir, no hay certeza sobre la información con la que se cuenta ni del resultado de las decisiones que tomemos. Los humanos analizamos la información con la que contamos y tomamos decisiones bajo incertidumbre; por ejemplo, un médico realiza un diagnóstico (inicial) aún cuando no tenga toda la información del caso y toma decisiones respecto al tratamiento. Si posteriormente tiene mayor información puede revisar sus conclusiones y modificar sus decisiones.

Los sistemas inteligentes deben ser también capaces de tomar decisiones bajo incertidumbre; y para ello es necesario desarrollar mecanismos computacionales que permitan representar y razonar con incertidumbre. Las representaciones basadas en esquemas

deterministas (como la lógica y los sistemas de reglas) en general no son capaces de lidiar con incertidumbre, por lo que se requieren otros esquemas no deterministas.

La teoría de probabilidad provee un marco adecuado para representar y razonar con incertidumbre; y aunque hay otras teorías, como la lógica difusa, la probabilidad tiene una mayor tradición así como fundamentos y métodos bien establecidos. Sin embargo, si se aplica en forma directa implica una alta complejidad computacional, lo cual frenó su desarrollo en los inicios de la computación, en particular en el área de inteligencia artificial y sistemas expertos.

El surgimiento de las redes bayesianas [12], así como de otros paradigmas relacionados, en los 80's del siglo pasado, hizo posible el desarrollo de métodos computacionales eficientes para la representación de conocimiento e inferencia basadas en probabilidad. La idea esencial es representar las relaciones de dependencia e independencia entre las variables de cierto problema, lo cual hace posible ahorros importantes en el espacio (memoria) y cómputo (operaciones) requeridas para modelar problemas complejos.

3.2. Modelos Gráficos Probabilistas

3.2.1. Redes Bayesianas

Esencialmente una **red bayesiana** representa, mediante un grafo dirigido, las relaciones de dependencia entre un conjunto de variables relevantes para cierto dominio. Por ejemplo, la Figura 3.1 ilustra un ejemplo muy simplificado de un problema de diagnóstico médico. Este modelo representa un conjunto de relaciones de dependencia: la fiebre y el dolor dependen de tener gripa o tifoidea. Las reacciones dependen también de esta última, y que la tifoidea depende de haber comido alimentos de procedencia dudosa. Lo más importante es que implícitamente se representan una serie de relaciones de independencia condicional; por ejemplo, comida y reacciones son independientes dado tifoidea, fiebre y dolor son independientes dado gripe, etc. Además, se asocian al

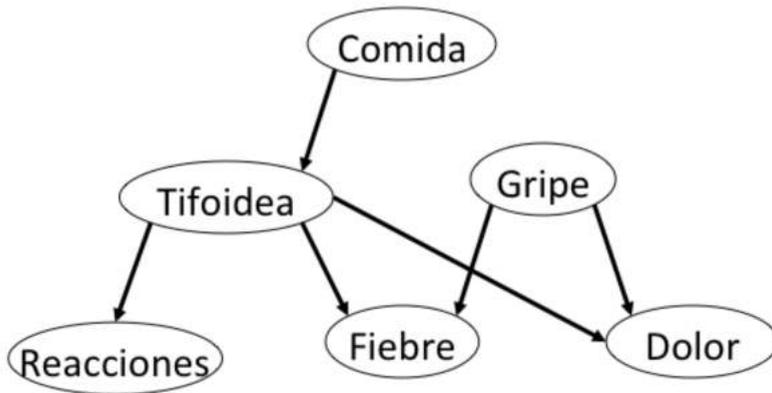


Figura 3.1: Ejemplo de una red bayesiana. Los nodos (óvalos) representan las variables y los arcos las relaciones de dependencia directa entre las variables.

grafo una serie de parámetros locales que representan las probabilidades asociadas (básicamente la probabilidad condicional de cada variable dados sus padres en el grafo). Dada la red bayesiana de un problema, se puede realizar razonamiento probabilista que consiste en estimar las probabilidades de ciertas variables de interés dadas otras variables conocidas. En el ejemplo de la figura, podríamos conocer fiebre y dolor y querer estimar la probabilidad de Tifoidea y Gripe. Este mecanismo de razonamiento se basa en la aplicación de la regla de Bayes, por ejemplo: $P(Tifoidea \mid Fiebre \wedge Dolor)$, y aprovechando la estructura de la red bayesiana este cálculo se puede hacer en forma muy eficiente incluso para modelos con cientos o miles de variables (mientras la topología del grafo no sea muy densa). También se han desarrollado algoritmos para aprender estos modelos a partir de datos, incluyendo la estructura y los parámetros. Existen otros tipos de modelos además de las redes bayesianas que se basan en los mismos principios –un grafo que representa las dependencias entre variables y parámetros locales asociados, así como mecanismos eficientes de inferencia– que en general podemos englobar bajo el término de Modelos Gráficos Probabilistas [16]. Dentro de estos se incluyen los modelos ocultos de Markov, los campos de Markov, los clasificadores bayesianos, las redes bayesianas

dinámicas, así como representaciones que incorporan decisiones y utilidades como los diagramas de influencia y los procesos de decisión de Markov. Se han desarrollado lenguajes de programación que facilitan la implementación de estos modelos como es el API ProBT que implementa la Programación Bayesiana [2].

3.2.2. Programación Bayesiana

La programación bayesiana es una metodología y formalismo que permite especificar y resolver modelos probabilistas; este paradigma está basado en los estudios de Edwin T. Jaynes ¹, quien propuso que la probabilidad puede ser considerada como una alternativa y una extensión del razonamiento lógico con información incompleta e incierta. La programación bayesiana puede ser vista como un formalismo algebraico para expresar modelos gráficos probabilistas como lo son las redes bayesianas, las redes bayesianas dinámicas, los filtros de Kalman, los modelos ocultos de Markov, y filtros de partículas entre otros. Un programa bayesiano permite especificar las distribuciones de probabilidad incluidas en un modelo y de realizar “preguntas”.

Los componentes de un programa bayesiano son los siguientes: una descripción y una pregunta. La descripción está constituida por una especificación (proporcionada por el programador) y una identificación o fase de aprendizaje de aquellos parámetros que no fueron especificados completamente en el modelo y que provienen de un conjunto de datos.

La especificación está construida por un conjunto de variables pertinentes, una descomposición y un conjunto de formas. Las formas son paramétricas o bien el resultado de una pregunta a un modelo bayesiano. La pregunta designa la distribución de probabilidad que debe ser calculada. Los elementos de un programa bayesiano están representados en la Figura 3.2.

¹Probability Theory: The Logic of Science. E. T. Jaynes, G. Cambridge University Press,

$$\text{Programa Bayesiano} = \left\{ \begin{array}{l} \text{Descripción} = \left\{ \begin{array}{l} \text{Especificación} = \left\{ \begin{array}{l} \text{Variables} \\ \text{Descomposición} \\ \text{Formas} \end{array} \right. \\ \text{Identificación} \end{array} \right. \\ \text{Pregunta} \end{array} \right.$$

Figura 3.2: Componentes de un Programa Bayesiano.

Los modelos gráficos probabilistas tienen su equivalente bajo el paradigma de la programación bayesiana, por ejemplo, los filtros o modelos ocultos de Markov son expresados como programas bayesianos recursivos.

Vale la pena señalar que la programación bayesiana busca no sólo tener una metodología para construir los modelos probabilistas sino también nuevos algoritmos de inferencia y lenguajes que automaticen el cálculo probabilista en las computadoras. Un ejemplo de dicho lenguaje es precisamente el API ProBT el cual está disponible en los lenguajes de programación C++ y Python. Para ejecutar estos algoritmos de forma eficiente, la programación bayesiana tiene como uno de sus objetivos la creación de nuevo hardware especializado. Para mayor información, el lector puede visitar la página bayesian-programming.org.

3.2.3. Clasificadores Bayesianos

Un caso especial de una red bayesiana es el clasificador *Naive Bayes* o clasificador bayesiano “ingenuo”, que hace uso de esta suposición de independencia y que arroja muy buenos resultados para un gran número de problemas. Un ejemplo de ello es la fusión de sensores. Este modelo consiste en determinar, a partir de un conjunto de *atributos*, el valor más probable de la *clase*, como una distancia, temperatura, presión, etc. Por ejemplo, un sensor realiza una medida con un nivel de incertidumbre con respecto al verdadero valor. Supongamos que la verdadera distancia a un objeto está dada por la variable D que es medida por n sensores. Al medir la distancia al objeto con los senso-

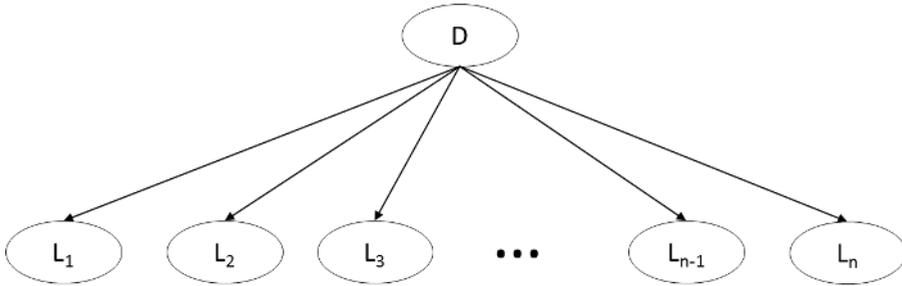


Figura 3.3: Representación gráfica de un modelo “Naive Bayes” para la estimación de la distancia D por medio de un conjunto de sensores que arrojan las lecturas L_1, L_2, \dots, L_n .

res, estos arrojan las lecturas L_1, L_2, \dots, L_n . La descomposición del modelo bayesiano es entonces,

$$P(D \wedge L_1 \wedge L_2 \dots L_n) = \\ P(D)(L_1|D)P(L_2|D \wedge L_1)P(L_3|D \wedge L_1 \wedge L_2) \dots P(L_n|D \wedge L_1 \wedge L_2 \dots L_{(n-1)})$$

Sin embargo, podemos suponer la independencia entre las variables de lectura:

$$P(L_i|D \wedge L_{(i-1)} \dots L_1) = P(L_i|D)$$

y usar el siguiente modelo:

$$P(D \wedge L_1 \wedge L_2 \dots L_n) = P(D)(L_1|D)P(L_2|D)P(L_3|D) \dots P(L_n|D)$$

Esta descomposición tiene una fuerte suposición de independencia entre las variables; sin embargo, es muy sencillo y en muchas ocasiones funciona mejor que otros modelos sofisticados, su representación gráfica es mostrada en la Figura 3.3.

Enseguida ejemplificamos el uso del clasificador *Naive Bayes* para determinar la distancia más probable a un objeto. Para este ejemplo, suponemos que la distancia es me-

dida con tres sensores obteniendo las lecturas L_1 , L_2 , y L_3 las cuales tienen una distribución Gaussiana con media igual a la distancia D y con varianzas 15, 12 y 10, respectivamente. Así, el objetivo es calcular $P(D|L_1 \wedge L_2 \wedge L_3)$; es decir, obtener la distribución de probabilidad de la distancia sabiendo las lecturas de los sensores. Suponga que se han obtenido los valores de 43, 45 y 40 como lectura para los sensores 1, 2 y 3, respectivamente. La Figura 3.4 ilustra las distribuciones de probabilidad generadas a partir de las lecturas y la distribución buscada $P(D|L_1 = 43 \wedge L_2 = 45 \wedge L_3 = 40)$. A partir de esta distribución se obtiene el valor más probable de la distancia que es 42.

3.2.4. Modelos Dinámicos

Los modelos gráficos probabilistas se pueden extender para representar procesos dinámicos. Uno de los modelos más usados para el diagnóstico y la predicción son las cadenas o modelos de Markov [16]. Dichos modelos han sido utilizados con éxito en un sin número de problemas entre estos se encuentra el reconocimiento de voz, la navegación en robótica, el modelado de proteínas, la predicción de navegación web, la predicción de inversiones en la bolsa, el reconocimiento de ademanes, etc. Existen varios modelos de Markov que se clasifican de acuerdo a la información que puede ser observada. Todos estos modelos están basados en la propiedad de Markov que establece que el valor presente de una variable aleatoria es el único valor (de esa variable) que establece la distribución de probabilidad del su próximo valor E_{i+1} . Es decir, los estados previos que haya tomado la variable, $E_{i-1}, E_{i-2}, \dots, E_0$, no tienen influencia para el nuevo estado (el futuro es independiente del pasado dado el presente).

Para explicar los modelos Markovianos consideremos el siguiente ejemplo. Suponga que tenemos un laboratorio con 4 cuartos: A, B, C y D, como se muestran en la Figura 3.5(a) (izquierda). En este laboratorio hay un robot vigilante que después de permanecer 5 minutos en una de las piezas tiene dos opciones: i) pasar a otra pieza usando las puertas 1 a 5, o ii) permanecer en la habitación en la que se encuentra. La probabilidad de su cambio de pieza o permanencia está expresado por el grafo de la Figura 3.5(b) (derecha).

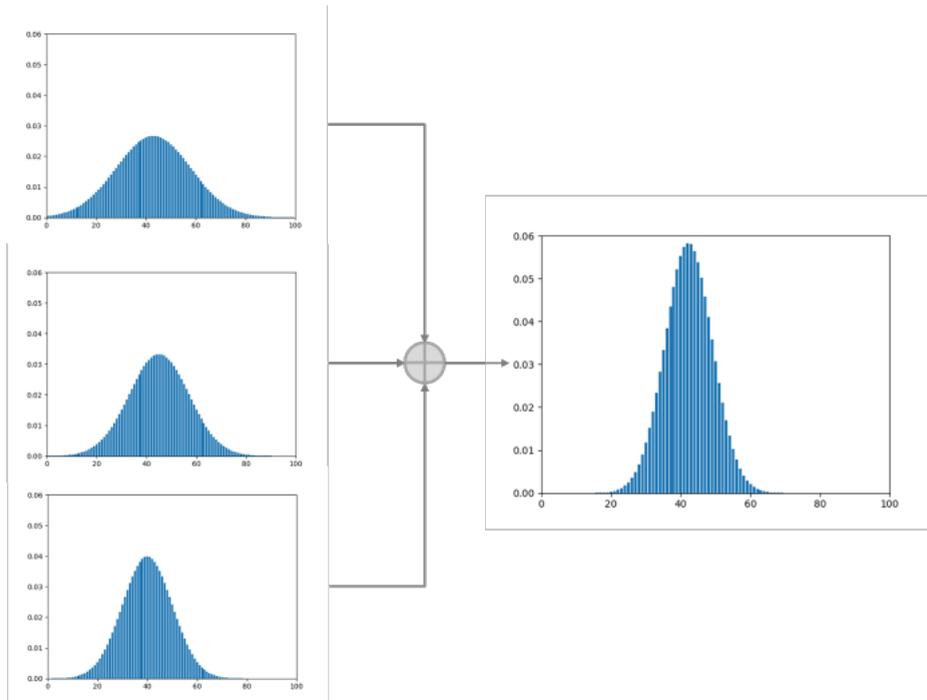


Figura 3.4: A partir de las mediciones 43, 45 y 40 de los tres sensores (izquierda) se obtiene la distribución de probabilidad de la distancia D al calcular $P(D|L_1 = 43 \wedge L_2 = 45 \wedge L_3 = 40)$, gráfica de la derecha. Con esta distribución podemos obtener el valor más probable de la distribución, en este caso 42.

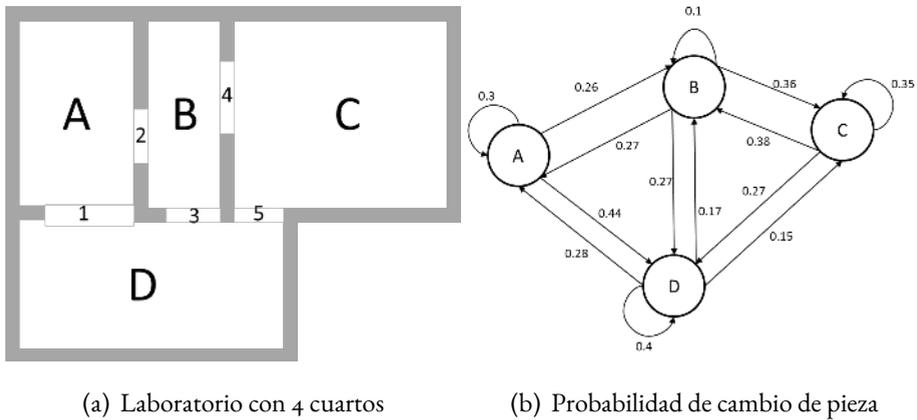


Figura 3.5: En un laboratorio se mueve un robot que pasa de una pieza a otra (A, B, C y D) usando las puertas 1 a 5 o bien permanece en la habitación (a). Las probabilidades de pasar de una a otra pieza o de permanecer en ella están expresadas por el grafo de la derecha (b). Por ejemplo, la probabilidad de pasar de la pieza A a la pieza B es de 0.26, de A a D de 0.44 y de permanecer en A de 0.3.

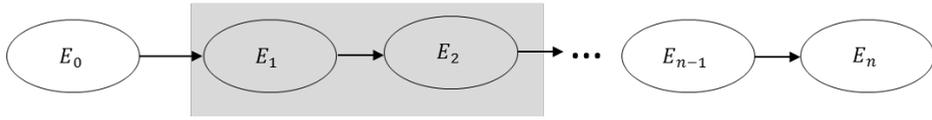


Figura 3.6: Representación gráfica del modelo cadena de *Markov*. Note que el modelo de n estados de la variable requiere únicamente de expresar la distribución conjunta de una “rebanada” del modelo completo, es decir $P(E_{t-1} \wedge E_t) = P(E_{t-1})P(E_t|E_{t-1})$ mostrada en la parte sombreada.

El más sencillo de los modelos de *Markov* es precisamente este ejemplo y se le conoce como “cadena de Markov”. Este modelo es expresado con dos variables, la del estado anterior E_{t-1} y la del estado presente E_t . La distribución conjunta de tal modelo es entonces,

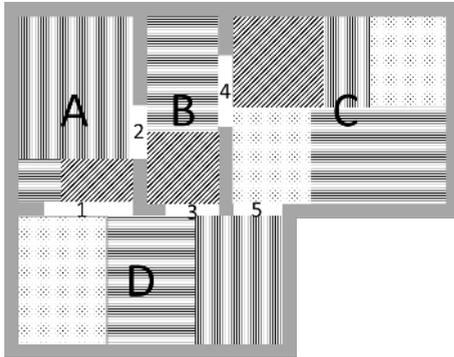
$$P(E_{t-1} \wedge E_t) = P(E_{t-1})P(E_t|E_{t-1})$$

Donde $P(E_{t-1})$ es la probabilidad de encontrarse en alguno de los estados A, B, C o D y $P(E_t|E_{t-1})$ es la probabilidad de transición entre los estados (ver parte derecha de la Figura 3.5). El modelo gráfico para n estados de una cadena de *Markov* es representado por la Figura 3.6, que contiene las distribuciones de probabilidad de la variable aleatoria en el tiempo.

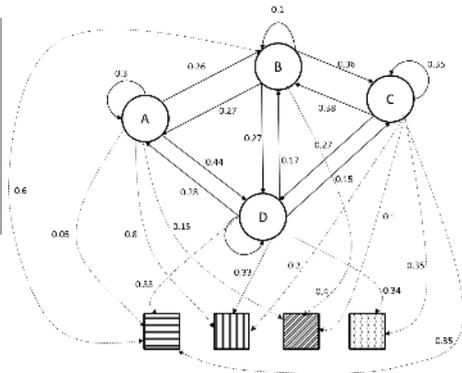
Note que el modelo de n estados de la variable requiere únicamente de expresar la distribución conjunta de una “rebanada” del modelo completo mostrada en el recuadro. Aun si gráficamente representamos varias variables E_0, E_1, E_2, \dots , es claro que se trata de la misma variable representando la posición del robot a través del tiempo. A partir de $P(E_{t-1} \wedge E_t) = P(E_{t-1})P(E_t|E_{t-1})$ es posible calcular la probabilidad de realizar un trayecto dado, por instancia $P(E_0 = C \wedge E_1 = D \wedge E_2 = A \wedge E_3 = A)$.

Ahora suponga que el robot puede realizar observaciones después de moverse de una pieza a otra o permanecer en ella. Suponga que al realizar una transición el robot se mueve a una posición de la pieza de manera aleatoria uniforme y observa el piso de la

habitación, gracias a una cámara colocada debajo de sus ruedas. Cada habitación tiene varios tipos de piso con patrones distintos como se muestra en la Figura 3.7(a). Por lo tanto, en una pieza dada se puede observar con, cierta probabilidad, cada uno de ellos: 1) vertical, 2) horizontal, 3) diagonal o 4) puntos. Al grafo de transición de la Figura 3.5 le agregamos entonces los arcos que representan las observaciones para cada pieza como se muestra en la Figura 3.7(b) da del modelo completo, es decir mostrada en la parte sombreada.



(a) Laboratorio con 4 cuartos



(b) Probabilidad de cambio de pieza

Figura 3.7: Se muestra un escenario similar al de la Figura 3.5 (izquierda), pero ahora el robot no sabe con certeza en que cuarto (estado se encuentra), puede tener una idea probabilística observando el piso. Del lado derecho se ilustra el diagrama de estados correspondiente, que además de incluir las probabilidades de transición de los estados, considera las probabilidades de las observaciones (cuadros inferiores) dado el estado.

Este nuevo modelo lleva como nombre Modelo Oculto de Markov o HMM por sus siglas en inglés (*Hidden Markov Model*), ya que los estados no son directamente

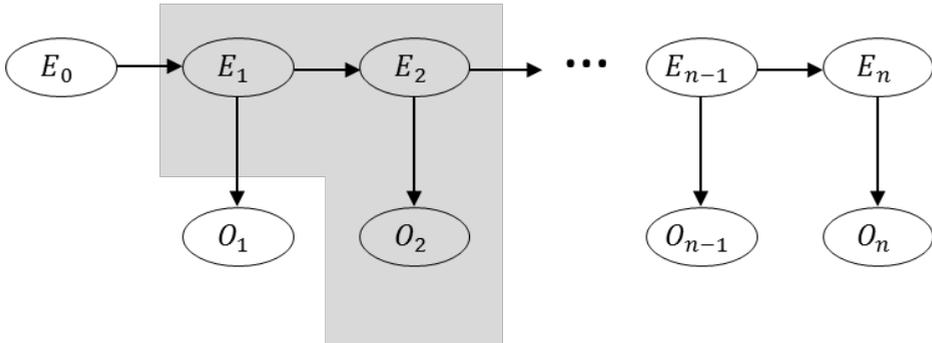


Figura 3.8: Representación gráfica de un modelo oculto de Markov (HMM). El modelo sólo requiere del establecimiento de una “rebanada” en el tiempo (zona sombreada) correspondiente a $P(E_{t-1} \wedge E_t \wedge O_t) = P(E_{t-1})P(E_t|E_{t-1})P(O_t|E_t)$.

conocidos, están “ocultos”. La distribución conjunta para dicho modelo es la siguiente:

$$P(E_{t-1} \wedge E_t \wedge O_t) = P(E_{t-1})P(E_t|E_{t-1})P(O_t|E_t)$$

Análogamente a la cadena de Markov, podemos calcular la probabilidad del estado actual del robot (un diagnóstico) cuando este se ha movido n veces realizando n observaciones $O_1, O_2, \dots, O_{(n-1)}, O_n$ al calcular $P(E_n|O_1 \wedge O_2, \dots, O_{(n-1)} \wedge O_n)$. Igualmente se puede calcular la probabilidad de haber ejecutado una secuencia a partir de las observaciones, eso es $P(E_1 \wedge E_2 \dots E_{(n-1)} \wedge E_n|O_1 \wedge O_2 \dots O_{(n-1)} \wedge O_n)$. La representación gráfica del modelo oculto de Markov se muestra en la Figura 3.8.

3.3. Principales Desarrollos en México

3.3.1. Academia

En el sector académico en México los desarrollos en este campo inician en los 90’s del siglo pasado a través de una colaboración entre el Instituto de Investigaciones Eléctricas, la

Universidad de Salford (Inglaterra) y el Tec de Monterrey–Cuernavaca. Posteriormente surgen otros grupos en el Instituto Nacional de Astrofísica, Óptica y Electrónica, el Tec de Monterrey–Monterrey y Ciudad de México, el Tecnológico de Acapulco y la Universidad Veracruzana, entre otros. En estos grupos se han desarrollado diversos proyectos en este tipo de modelos, tanto en aspectos más técnicos como en aplicaciones, incluyendo varias tesis doctorales. Uno de los principales logros ha sido el llevar a diversas aplicaciones novedosas y realistas los modelos gráficos probabilistas, incluyendo:

- La aplicación de redes bayesianas en análisis de confiabilidad de sistemas complejos [17]. Fue el primer trabajo en esta área en el mundo y dio origen a una línea de investigación con talleres y congresos propios.
- El uso del esquema de validación de información basado en redes bayesianas en diversos dominios, incluyendo plantas eléctricas, transformadores, fabricación de tubos de acero y campos petroleros [9].
- La aplicación de las redes de eventos temporales en diagnóstico de plantas eléctricas y la predicción de mutaciones del virus del VIH [7].
- El reconocimiento de ademanes con modelos ocultos de *Markov* y redes bayesianas dinámicas; el grupo fue uno de los pioneros en esta aplicación, la cual es muy utilizada actualmente [1].
- La adaptación de sistemas de rehabilitación virtual basada en procesos de decisión de *Markov* [11].
- La aplicación de Campos de *Markov* para mejorar los procesos de anotación y recuperación de imágenes [6].
- El uso de redes bayesianas y diagramas de decisión para la selección de pozos para inyección en campos petroleros maduros.

- Modelado del estudiante para tutores inteligentes, incluyendo modelos relacionales probabilistas para laboratorios virtuales, representación del estado afectivo del estudiante basado en redes de decisión y un modelo basado en redes de decisión dinámicas para la secuencia y navegación de objetos de aprendizaje en ambientes de educación en línea [15].
- Modelos para planeación basados en procesos de decisión de *Markov* que permiten coordinar robots de servicio al realizar tareas complejas, incluyendo un esquema para realizar acciones concurrentes y resolver conflictos [3].

Otro logro relevante es el desarrollo de herramientas de software genéricas, tales como VALIDATOR [8] (herramienta para validar información en bases de datos, que puede detectar y corregir diferentes tipos de errores), clasificadores bayesianos, semi-bayesianos, multi-dimensionales [4] y jerárquicos [13], que se han incorporado a las herramientas abiertas WEKA/MEKA ². Otros desarrollos incluyen AsistO [14] (sistema para ayuda de operadores de plantas eléctricas), PROMODEL [10] (ambiente Web orientado a servicios y dirigido por modelos para el desarrollo de sistemas bajo incertidumbre que permite generar aplicaciones Web de forma automática). También se publicó un libro sobre programación bayesiana [2] y otro sobre modelos gráficos probabilistas y sus aplicaciones [16].

3.3.2. Gobierno, industria y empresas

En México la explotación de aplicaciones basadas en modelos probabilistas es limitada y más aún es su desarrollo comercial. En nuestro país, muy probablemente es el sector financiero el que más aprovecha el razonamiento probabilista, en la mayoría de los casos, usando software de origen extranjero. Por ejemplo, empresas globales como *SAS Institute* e *IBM* han integrado con éxito una diversidad de algoritmos y modelos en sus

²<http://www.cs.waikato.ac.nz/ml/weka/>

herramientas, los cuales son comúnmente usado por las instituciones financieras que operan en México y otras grandes organizaciones.

En este sector, el financiero, existe gran interés por desarrollar aplicaciones y modelos bayesianos nacionales. Así lo demuestran los trabajos que usan las redes bayesianas para el cálculo de riesgo operacional en relación a las actividades de bancos internacionales. Dichos modelos usan datos históricos que reflejan los eventos ocurridos en las diferentes líneas de negocios de las instituciones financieras³. Otro ejemplo, son los trabajos con enfoque bayesiano para el suavizamiento de series de tiempo económicas⁴ y que hace uso de los métodos de estimación Monte Carlo basado en cadenas de *Markov*. Esta metodología es usada para la toma de decisiones en los ciclos de negocios, particularmente para analizar tendencias a corto y largo plazo. Existe también interés por llevar el razonamiento probabilista al sector de gobierno, un ejemplo es la generación bayesiana de tablas de mortalidad⁵ las cuales son calculadas por la Comisión Nacional de Seguros y Fianzas (CNSF)⁶ institución que supervisa que la operación de los sectores asegurador y afianzador se apege al marco normativo, preservando la solvencia y estabilidad financiera de las instituciones de Seguros y Fianzas. Si bien el método aún no es adoptado por la CNSF los resultados sugieren que es conveniente y de utilidad a corto plazo.

³Riesgo operacional en la banca transnacional: un enfoque bayesiano. José Francisco Martínez-Sánchez, Francisco Venegas-Martínez, Ensayos Revista de Economía–Vol XXXII, No.1, mayo 2013, pp. 31-72.

⁴A Bayesian Approach to the Hodrick-Prescott Filter, Enrique de Alba y Sergio Gómez, Realidad, Datos y Espacio, Revista Internacional de Estadística, Vol. 3 Núm. 3 septiembre-diciembre 2012.

⁵Inferencia bayesiana y tablas de mortalidad en México, Manuel Mendoza Ramírez, Alberto Contreras Cristián y Eduardo Gutiérrez Peña. Realidad, Datos y Espacio, Revista Internacional de Estadística. Vol.6, Núm. 1, enero-abril 2015.

⁶Órgano Desconcentrado de la Secretaría de Hacienda y Crédito Público.

Dejando aparte el sector financiero, en México, las oportunidades más significativas para la explotación de aplicaciones comerciales nacionales de razonamiento probabilista se encuentra en dos nichos: (i) en las pequeñas y medianas empresas y (ii) en las grandes empresas donde existe una necesidad particular que no requiere de la aprobación a nivel corporativo. En efecto, para las grandes organizaciones de capital extranjero, las directivas referentes al uso de software son por lo general establecidas por el corporativo. Es decir, si una organización de capital extranjero en México usa una herramienta es porque esta fue aprobada por la más alta esfera fuera de México. Lo anterior, provoca que el software análogo de desarrollo nacional tenga pocas posibilidades de ser adoptado. Las aplicaciones bayesianas de desarrollo nacional se encuentran con dos barreras principales para ser empleadas por las grandes empresas: (i) la gran dificultad a ser aprobadas por el corporativo y (ii) la dificultad para competir con empresas globales.

A pesar de todas las dificultades que enfrenta la metodología para su desarrollo nacional comercial, existen empresas que invierten en esta tecnología y que ofrecen productos o servicios relacionados con el razonamiento probabilista. De acuerdo a nuestro mejor conocimiento, las empresas mexicanas que desarrollan sistemas basados en el razonamiento probabilista son las siguientes: Promagnus S.A. de C.V. (antes Probayes Américas S.A. de C.V.), Cytron Medical S. A. de C. V. y Sistemas Box S.A. de C.V.

Promagnus S.A. de C.V.⁷ ofrece una serie de productos y servicios basados en el razonamiento bayesiano. Dentro de sus productos más sobresaliente se encuentran aquellos que hacen uso de la visión por computadora. La empresa cuenta con sistemas sumamente eficientes para el conteo de vehículos o personas basados en un filtro bayesiano. La aplicación es usada para auditorías de peajes, conteo en estacionamientos y medición de grado de actividad en centros comerciales, entre otros. Además, comercializa un sistema para la administración de flujo de materiales en manufactura esbelta. Dicho sistema permite definir y supervisar el flujo continuo de abastecimiento de materiales dentro de una cadena de suministro para procesos de manufactura. El software identi-

⁷<http://www.promagnuscompany.com>

fica los diferentes vehículos utilitarios, carritos industriales o montacargas encargados de la entrega de materiales en el flujo de producción con el objetivo de optimizar el análisis de: tiempo de recorrido por vehículos, cumplimiento de rutas, puntos de conflicto y re-abastecimiento oportuno. Otros productos son comercializados por la empresa Promagnus como lo son el conteo automático de piezas y un sistema *Pick-to-Light* el cual dirige a operadores en procesos de armado dirigiéndolos automáticamente al lugar de donde deben tomar las piezas (realizar el *picking*). El sistema detecta la extracción y muestra el siguiente emplazamiento registrando estadísticas para su análisis. En lo que respecta al Internet de las Cosas, la empresa comercializa un sistema que recopila y analiza, en tiempo real, información de diferentes tipos de sensores. La aplicación es capaz de lanzar alarmas por comportamientos anormales y activar actuadores gracias a la definición de reglas. En lo que respecta a servicios, Promagnus ofrece consultoría y desarrollo, análisis de datos y conexión de dispositivos para el Internet de las Cosas.

Durante la epidemia de H1N1 en Yucatán, la empresa Cytron Medical S. A. de C. V. (www.cytron.com.mx) decidió incursionar en uso de modelos predictivos basados en redes bayesianas para integrar la incipiente información de las unidades de salud remotas. Se desarrollaron varios modelos genéricos que incluían fundamentalmente series de tiempo históricas sobre humedad, precipitación, urbanística, calidad de agua, etc. como elementos básicos para la propagación de los vectores transmisores de dichas enfermedades. Durante los siguientes tres años se fueron alimentando las redes bayesianas inicialmente desarrolladas para H1N1 y hoy en día están en desarrollo modelos predictivos que incluyen aspectos de geo-referenciación involucrando fuentes de información de lo denominado *people analytics* para incorporar restricciones relacionadas con actividades y concentraciones poblacionales. Las metodologías desarrolladas han derivado en dos productos principales; el primero sobre una plataforma de redes genéricas y la segunda sobre redes particulares. Como ejemplo de red particular tenemos el caso de la red bayesiana para la predicción de apariciones de brotes de dengue tomando en cuenta

medidas de humedad, precipitación pluvial y el índice pupal, el cual mide la cantidad de huevos del mosquito que existen en el ambiente.

Por otra parte, la empresa ha desarrollado productos de software para el análisis de quemaduras corporales, del cual se cuenta con la patente No. 335934. En ésta se describen los algoritmos de procesamiento digital de imágenes y minería de datos para poder realizar la detección de una quemadura en el cuerpo y dar una guía para su atención temprana. En alianza con varios hospitales del país, la empresa ha conformado bases de datos de imágenes cuyo análisis permitiría clasificar las quemaduras por grados usando la información de extensión y profundidad. Se han incluso previsto métricas de los diferentes tipos de piel y los procesos de cicatrización para crear redes bayesianas lo que derivará en resultados más confiables.

Sistemas Box S.A. de C.V. (sistemasbox.com) es una empresa líder en el desarrollo de software en el sector automotriz en México, y ha dirigido sus esfuerzos hacia la medición del denominado efecto *Bullwhip* y la generación de rutas y órdenes de visita para el recorrido óptimo de vehículos de reparto en última milla. El efecto *Bullwhip* (o efecto látigo) es la fluctuación de los pedidos a lo largo de una cadena de suministro donde las órdenes al proveedor tienen mayor varianza que las ventas al comprador causando incertidumbre en todo el proceso. Algunas de sus causas son: el hermetismo con respecto a la información de la demanda entre los miembros de la cadena de suministro, el miedo a quedarse con déficit de inventario, fluctuación de precios, largos períodos de entrega, entre otros factores. Si bien existen diversas soluciones que permiten modelar el problema dentro de una cadena tradicional, Sistemas Box ha elegido medir la fluctuación de los pedidos con respecto a la demanda y ha utilizado un modelo de redes bayesianas para la determinación del pronóstico de la demanda. Este modelo permite pronosticar las ventas en los períodos siguientes a partir de variables relacionadas con las refacciones y con factores geográficos o estacionales en que se realizan las ventas. Ya que el efecto bullwhip ocasiona retrasos en el surtido de inventario por parte de los proveedores, Sistemas Box desarrolló un motor de rutas que se compone de un módulo de

generación de órdenes de visita óptimo VRP (*Vehicle Routing Problem*) el cual a su vez utiliza un módulo de generación de rutas punto a punto (P2P). El módulo VRP utiliza la ubicación de los centros de distribución (CEDIS), los puntos de inicio y finalización del recorrido, las características de los vehículos, almacenes y CEDIS. Con esta información genera una orden de visita para surtir producto desde los almacenes a los CEDIS. Para esto se utiliza *Tabu Search* (TS), un algoritmo heurístico de optimización combinatoria que se basa en la búsqueda de un óptimo local a partir de una solución inicial con la restricción de no permitir movimientos a una solución que no sea mejor que las anteriores. El módulo P2P utiliza un algoritmo de búsqueda *Dijkstra* para encontrar la ruta más cercana a partir de un nodo de inicio hasta un nodo final en un grafo.

A las empresas anteriores, que son de capital 100 % mexicano, se suma Bayes Forecast (www.bayesforecast.com) una empresa multinacional con presencia en México desde el 2009 dedicada a la generación de inteligencia mediante soluciones tecnológicas basadas en analítica avanzada. La empresa es experta en la implementación de metodologías bayesianas orientadas a potencializar modelos matemáticos con el conocimiento operativo de las empresas. La compañía cuenta con más de 25 años de experiencia otorgando soluciones *ad-hoc* para la industria, especializándose en consumo, banca y telecomunicaciones. Con su base en Madrid, también opera con oficinas en la Ciudad de México y Sao Paulo, Brasil. La mayoría de los empleados de *Bayes Forecast* cuenta con una formación en ciencias exactas (matemáticas, actuaría, ingenierías, y afines) y con experiencia en la aplicación práctica de modelos a situaciones reales de negocio. Las soluciones ofrecidas utilizan tecnologías de punta y programación computacional avanzada para entregar simuladores, tableros de control, optimizadores, aplicaciones, elasticidades, descomposiciones, etc.

3.4. Retos y Perspectivas Futuros

A futuro se vislumbran diversos dominios en que estos modelos se pueden aplicar para resolver problemas en que hay mucha incertidumbre, incluyendo aplicaciones en salud, el sector energía, juegos (serios y de entretenimiento), robótica de servicio, sector financiero, etc.

Un área interesante que está creciendo en el mundo es el de los modelos gráficos causales, que no solo representen relaciones de dependencia estadística, sino relaciones causa-efecto. En México se está empezando a incursionar en esta área en el modelado de las relaciones de conectividad efectiva en el cerebro mediante redes bayesianas causales, así como en modelos predictivos para la detección temprana de fragilidad en los adultos mayores. Este tema se analiza a más detalle en el siguiente capítulo.

Otra área en desarrollo es la combinación de representaciones basadas en lógica de predicados y representaciones probabilistas, de forma de tener lo mejor de los dos mundos: alta expresividad y manejo de incertidumbre [5]. Estas representaciones se conocen como modelos relacionales probabilistas y existen diversas variantes de estos modelos. En México se han aplicado estos modelos al reconocimiento de objetos en imágenes.

Bibliografía

- [1] H.H. Avilés-Arriaga, L.E. Sucar-Succar, C.E. Mendoza-Durán, and L.A. Pineda-Cortés. A Comparison of Dynamic Naive Bayesian Classifiers and Hidden Markov Models for Gesture Recognition. *Journal of Applied Research and Technology*, 9(01), apr 2011. ISSN 2448-6736. doi: 10.22201/icat.16656423.2011.9.01.453. URL <http://www.jart.icat.unam.mx/index.php/jart/article/view/453>.

- [2] Pierre Bessiere, Emmanuel Mazer, Juan-Manuel Ahuactzin, and Kamel Mekhnacha. *Bayesian programming*. ISBN 9781439880326.

- URL <https://www.crcpress.com/Bayesian-Programming/Bessiere-Mazer-Ahuactzin-Mekhnacha/p/book/9781439880326>.
- [3] Elva Corona and L. Enrique Sucar. Task Coordination for Service Robots Based on Multiple Markov Decision Processes. In *Decision Theory Models for Applications in Artificial Intelligence*, pages 343–360. IGI Global, 2012. doi: 10.4018/978-1-60960-165-2.ch015. URL <http://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/978-1-60960-165-2.ch015>.
- [4] L. Enrique Sucar, Concha Bielza, Eduardo F. Morales, Pablo Hernandez-Leal, Julio H. Zaragoza, and Pedro Larrañaga. Multi-label classification with Bayesian network-based chain classifiers. *Pattern Recognition Letters*, 41(C):14–22, may 2014. ISSN 01678655. doi: 10.1016/j.patrec.2013.11.007. URL <https://linkinghub.elsevier.com/retrieve/pii/S0167865513004303>.
- [5] Lise Getoor and Ben Taskar. *Introduction to statistical relational learning*. MIT Press, 2007. ISBN 9780262072885.
- [6] Carlos Arturo Hernández-Gracidas, Luis Enrique Sucar, and Manuel Montesy Gómez. Improving image retrieval by using spatial relations. *Multimedia Tools and Applications*, 62(2):479–505, jan 2013. ISSN 1380-7501. doi: 10.1007/s11042-011-0911-1. URL <http://link.springer.com/10.1007/s11042-011-0911-1>.
- [7] Pablo Hernandez-Leal, Alma Rios-Flores, Santiago Ávila-Rios, Gustavo Reyes-Terán, Jesus A. Gonzalez, Lindsey Fiedler-Cameras, Felipe Orihuela-Espina, Eduardo F. Morales, and L. Enrique Sucar. Discovering human immunodeficiency virus mutational pathways using temporal Bayesian networks. *Artificial Intelligence in Medicine*, 57(3): 185–195, mar 2013. ISSN 09333657. doi: 10.1016/j.artmed.2013.01.005.

- URL <http://www.ncbi.nlm.nih.gov/pubmed/23561488><https://linkinghub.elsevier.com/retrieve/pii/S0933365713000079>.
- [8] Javier Herrera-Vega, Felipe Orihuela-Espina, Eduardo F. Morales, and Luis Enrique Sucar. A framework for oil well production data validation, 2012. URL <https://www.semanticscholar.org/paper/A-framework-for-oil-well-production-data-validation-Herrera-Vega-Orihuela/11a89ddf49c493a906313bb71393daf78f79b696>.
- [9] Pablo H. Ibargüengoytia, Sunil Vadera, and L. Enrique Sucar. A Probabilistic Model for Information and Sensor Validation. *The Computer Journal*, 49(1):113–126, jan 2006. ISSN 1460-2067. doi: 10.1093/comjnl/bxh142. URL <http://academic.oup.com/comjnl/article/49/1/113/419005/A-Probabilistic-Model-for-Information-and-Sensor>.
- [10] Rosa López-Landa and Julieta Noguez. *PRoModel*: a model-driven software environment that facilitates and expedites the development of systems that handle uncertainty. In *2012 Spring Simulation Multiconference, SpringSim '12, Orlando, FL, USA, March 26-29, 2012, Proceedings of the 2012 Symposium on Theory of Modeling and Simulation - DEVS Integrative Modelling Symposium*, page 41, 2012. URL <http://dl.acm.org/citation.cfm?id=2346657>.
- [11] Alberto L. Morán, Cristina Ramírez-Fernández, Victoria Meza-Kubo, Felipe Orihuela-Espina, Eloísa García-Canseco, Ana I. Grimaldo, and Enrique Sucar. On the Effect of Previous Technological Experience on the Usability of a Virtual Rehabilitation Tool for the Physical Activation and Cognitive Stimulation of Elders. *Journal of Medical Systems*, 39(9):104, sep 2015. ISSN 0148-5598. doi: 10.1007/s10916-015-0297-0. URL <http://link.springer.com/10.1007/s10916-015-0297-0>.

- [12] Judea Pearl and Judea. *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann Publishers, 1988. ISBN 0934613737. URL <https://dl.acm.org/citation.cfm?id=52121>.
- [13] Mallinali Ramírez-Corona, L. Enrique Sucar, and Eduardo F. Morales. Chained Path Evaluation for Hierarchical Multi-Label Classification. *The Twenty-Seventh International Flairs Conference*, may 2014. URL <https://www.aaai.org/ocs/index.php/FLAIRS/FLAIRS14/paper/viewPaper/7779>.
- [14] Alberto Reyes, Alberto Reyes, L. Enrique Sucar, and Eduardo F. Morales. AsistO: A Qualitative MDP-based Recommender System for Power Plant Operation. *Computación y Sistemas*, 13(1):5–20, dec 2009. ISSN 2007-9737. doi: 10.13053/cys-13-1-1218. URL <https://www.cys.cic.ipn.mx/ojs/index.php/CyS/article/view/1218>.
- [15] L. Enrique Sucar and Julieta Noguez. Student Modeling. In *Bayesian Networks*, pages 173–185. John Wiley & Sons, Ltd, Chichester, UK. doi: 10.1002/9780470994559.ch10. URL <http://doi.wiley.com/10.1002/9780470994559.ch10>.
- [16] Luis Enrique Sucar. *Probabilistic graphical models: principles and applications*. ISBN 9781447166986. URL https://www.researchgate.net/publication/278963064_{_}Probabilistic_{_}Graphical_{_}Models_{_}Principles_{_}and_{_}A
- [17] José Gerardo Torres-Toledano and Luis Enrique Sucar. *Bayesian Networks for Reliability Analysis of Complex Systems*. pages 195–206. Springer, Berlin, Heidelberg, 1998. doi: 10.1007/3-540-49795-1_17. URL http://link.springer.com/10.1007/3-540-49795-1_{_}17.

Capítulo 4

Razonamiento estadístico

Ana Carmen Estrada Real

Instituto Tecnológico y de Estudios Superiores de Monterrey

Nora Patricia Hernández López

Instituto Tecnológico y de Estudios Superiores de Monterrey

4.1. Introducción

La estadística siempre ha estado profundamente ligada a la probabilidad, según la Real Academia Española es la rama de las matemáticas que utiliza grandes conjuntos de datos para hacer inferencias basadas en el cálculo de probabilidades. Por otro lado, también está definida como el estudio de los datos cuantitativos relativos a poblaciones, recursos y manifestaciones de sociedades humanas [14].

De la segunda definición entendemos la influencia de la estadística de manera histórica en el Estado. Durante mucho tiempo ha sido la motivación del desarrollo de esta disciplina, porque se utiliza para censos poblacionales, tasas de mortalidad, cálculo de

recursos y alimentos necesarios en los pueblos. Aunque también se ha utilizado en biología y astronomía desde antes el siglo XVIII [51].

Recientemente, con la invención del internet y la capacidad de generar grandes cantidades de datos en menos tiempo, junto con la creciente capacidad computacional; la estadística se ha convertido en la disciplina a la que se acude para validar modelos, información y nuevo conocimiento de cualquier disciplina en la que se analizan datos para hacer inferencias.

El razonamiento estadístico surge de la necesidad de conectar las dos dimensiones *económica y cognitiva*. Se necesitaba un sistema que pudiera representar relaciones entre costos y técnicas o fenómenos sociales. Ya que las ideas matemáticas tienen un efecto directo sobre decisiones del estado [22].

El estudio estadístico tiene su origen en la teoría de la probabilidad durante el siglo XVII, específicamente se desarrolla con el cálculo de valores esperados, lo cual abrió la posibilidad de hacer aserciones sobre eventos inciertos desde el punto de vista de las consecuencias. Más adelante, *Gauss* desarrolló un método general de estimación, el principio de mínimos cuadrados, con el objetivo de sintetizar los datos producto de sus observaciones astronómicas. Esto abrió la oportunidad para un estudio cuantitativo en áreas que son inherentemente productoras de datos en gran escala. Los primeros acercamientos de *Fisher* con el análisis de los fenómenos estadísticos ocurrieron con experimentos de agricultura y biometría. Posteriormente, su aplicación se extendió hacia el control de la calidad industrial, la milicia, ingeniería en general, psicología, negocios, y ciencias de la salud; aunque sin duda la estadística tuvo un auge gracias a la necesidad de análisis de políticas públicas y económicas [36].

En algún momento los estadistas fueron llamados *políticos aritméticos* por su fuerte influencia en el desarrollo social y la planeación gubernamental. Pero desde aproximadamente 1830 su influencia se colocaba en muchas otras ramas como astronomía, zoología, botánica, química y geología. Más tarde *Einstein* sería pionero de la mecánica estadística

que le ayudaría a desarrollar la teoría que le daría el premio nobel. En pocas palabras la estadística ha creado las leyes que gobiernan el caos [37].

Es así como la estadística es una manera de aplicar el método científico a inferencias humanas, en donde a partir de un conjunto de datos es posible extender el conocimiento más allá de ellos [26]. En este capítulo se explicarán algunos de los métodos estadísticos más utilizados y su algunas de las aplicaciones más importantes como en ciencia de datos, inteligencia artificial y aprendizaje a máquina.

4.2. ¿Qué es el razonamiento estadístico?

El razonamiento estadístico está definido por la capacidad humana para hacer interpretaciones y dar sentido a un conjunto de datos, que viene dado por el entendimiento de las representaciones y análisis estadístico de dichos datos [18]. Es de esta forma que las explicaciones que se dan combinan ideas sobre probabilidad y estadística, las cuales guían el proceso de reflexión e inferencia sobre los datos. Los conceptos que están intrínsecamente relacionados con el razonamiento estadístico son distribución, propagación, centralización, asociación, incertidumbre, aleatoriedad y muestreo [17]; los cuales serán descritos apropiadamente en los próximos párrafos.

4.2.1. Cómo pensar estadísticamente

El pensamiento estadístico está relacionado con la noción y descripción numérica de los eventos a nuestro alrededor [55]. Es una herramienta indispensable en la ciencia, y es objeto de interés de varias áreas como la psicología, las ciencias médicas, el periodismo de divulgación científica, así como el análisis político.

Es pertinente hacer la aclaración de que la estadística es una ciencia matemática por su cuenta, y no una rama de las matemáticas. Es el área encargada de ofrecer herramientas para tratar con la variabilidad en los datos [11], y por tanto el razonamiento estadístico no debe ser confundido con razonamiento matemático. Si bien es cierto que las

herramientas matemáticas, y en las últimas décadas también las herramientas computacionales, son utilizadas en los procedimientos estadísticos, la verdadera naturaleza de los problemas estadísticos reside en responder una o varias preguntas con soporte en hallazgos y suposiciones sobre un conjunto de datos, y más allá de una respuesta matemática correcta se busca que los métodos empleados sean adecuados a la naturaleza de los datos y evidencia dada [18].

Dentro del razonamiento estadístico, se pueden identificar varias habilidades específicas que se complementan [17]:

- Razonamiento sobre los datos. Busca reconocer y organizar los datos dada su naturaleza cualitativa o cuantitativa, discreta o continua, y las tablas, gráficas y medidas estadísticas pertinentes.
- Razonamiento sobre representaciones de datos. Es el entendimiento sobre por qué las diferentes medidas estadísticas reflejan diferente información acerca de los datos, y cómo utilizar estas medidas bajo diferentes situaciones o para comparar dos o más conjuntos de datos.
- Razonamiento sobre incertidumbre. Se refiere a la capacidad para hacer juicios sobre eventos inciertos dadas las nociones de aleatoriedad y probabilidad.
- Razonamiento sobre las muestras. Es el conocimiento sobre cómo se relaciona una muestra con la población, y qué se puede inferir con dicha muestra, así como la importancia de una muestra representativa.
- Razonamiento de asociación. Se refiere a la interpretación de la relación entre dos variables, y las implicaciones de la correlación entre éstas.

4.2.2. Incertidumbre y probabilidad en el razonamiento estadístico

La noción de incertidumbre está intrínsecamente relacionada con la modelación e inferencia estadística, pues su principal objetivo es cuantificar dicha incertidumbre a través de un análisis sistemático. La naturaleza de los problemas estadísticos es inherentemente inductiva pues requiere de un tratamiento lógico de la información observada y la evidencia dada. Al mismo tiempo, la elaboración de un modelo estadístico es una tarea más bien deductiva que, aunque precisa e invariable por su cuenta, nace de una resolución inherentemente incierta dado que se trata de condicionar elementos estocásticos provenientes de la naturaleza de los datos observados [36]. Bajo este paradigma existe la posibilidad de que un nuevo dato observado sea capaz de dismantelar una conclusión obtenida cuidadosamente con los procedimientos adecuados.

Pawitan [36] identifica dos modelos utilizados en el análisis de problemas estadísticos. El primero es de origen mecánico y se limita a explicar los intrincados mecanismos que subyacen en los datos y dan una explicación coherente a los datos observados. Un ejemplo de este tipo de modelo lo podemos encontrar en las leyes de Newton.

En contraste, la segunda clasificación se refiere a modelos que explican la variabilidad de los datos, en vez de dar una interpretación del mecanismo que los origina. Están basados en observaciones empíricas, y dado que la naturaleza de los fenómenos es compleja, un enfoque totalmente analítico resulta inapropiado. En esta categoría se encuentran los modelos utilizados en las ciencias aplicadas cuya base es más bien empírica.

Mientras que las diferencias son claras entre ambos tipos de modelos, no son mutuamente excluyentes, pues un modelo empírico puede dar origen a uno de tipo mecánico. Sin embargo, hay fenómenos que nunca podrán ser explicados por un modelo mecánico; por ejemplo, el número de personas infectadas con alguna enfermedad.

Para una adecuada representación del problema en un modelo, es pertinente tomar en cuenta que los problemas estadísticos están siempre limitados por cierta condición

de incertidumbre. Ésta puede estar relacionada con el tipo de modelo que se elige, con la capacidad de éste para generalizar los datos, el número y suficiencia de las variables medidas, si las preguntas que se están haciendo son las adecuadas, o si la muestra seleccionada es representativa. Para cuantificar la incertidumbre estadística, se pueden identificar dos clases [36]:

1. **Incertidumbre estocástica.** Está relacionada con una variable y su resultado. La forma en que se puede controlar es incrementando el tamaño de la muestra o el número de experimentos, pues está relacionada con los conceptos de distribución de la muestra, variabilidad, intervalo de confianza, o valor p .
2. **Incertidumbre inductiva.** Esta se debe a información incompleta, lo cual la convierte en imposible de medir o controlar.

Los enfoques Bayesianos y frecuentistas. La teoría de la inferencia tiene un rol fundamental en el estudio estadístico, pues permite responder preguntas dada la elección de un modelo pertinente y los datos como evidencia que lo respaldan. Al respecto, se pueden encontrar dos grandes paradigmas que abordan de manera distinta la probabilidad: como una creencia aceptada axiomáticamente, llamado Bayesiano, o como una frecuencia obtenida a través de muchas observaciones, conocido como frecuentista. El caso del acercamiento Bayesiano también es conocido como *probabilidad inversa*, que basado en el teorema de Bayes, supone un procedimiento puramente matemático para el problema de la inferencia inductiva. Sin embargo, la controversia persiste para la determinación de la probabilidad a priori del evento en cuestión. Por otro lado, el enfoque frecuentista también se basa en el principio del muestreo repetido para validar un modelo dada la observación de variables medibles. Muchos de los conceptos estadísticos ampliamente utilizados tienen su origen en esta metodología: sesgo, variabilidad, error estándar, valor p . Un enfoque unificado de ambas posturas lo da Fisher, que permite una reducción dada la función de verosimilitud [12]. Fisher desarrolló la noción

de la probabilidad fiducial como aquella inferencia objetiva sin la necesidad de una probabilidad a priori, pues, aunque no es posible verificar la función de verosimilitud, se pueden obtener propiedades probabilísticas con muestras lo suficientemente grandes. El método de reducción de Fisher primero encuentra la función de verosimilitud para reducirla a una estadística S de la cual se puedan derivar los valores de p para la hipótesis nula.

4.3. La estadística en la revolución de la ciencia de datos

La ciencia de datos ha surgido de la necesidad de análisis de las grandes bases de datos originadas a partir del uso del internet y la evolución de las técnicas de medición, incluyendo sensores y encuestas. Aprovechando la creciente capacidad computacional y la invención de algoritmos eficientes, se ha recurrido a la estadística y a las ciencias computacionales para crear técnicas de análisis de estos datos y modelos que permitan resolver problemas, visualizar resultados, comunicar mediciones y validar hipótesis con la posibilidad de ser reproducibles y colaborativos [9].

Nos encontramos actualmente en la cuarta fase de la historia de la ciencia. La primera fase fue empírica basada en la observación, la segunda en ciencias teóricas con fundamentos matemáticos, la tercera en simulaciones computacionales y la cuarta en descubrimientos a base de datos. Para que esto sea posible los datos deben estar auto-contenidos y estructurados. La figura 4.1 muestra los diferentes tipos de inferencia de datos, la inducción se refiere a descubrir la dependencia que existe en los datos y la deducción a poder predecir salidas de entradas desconocidas en un futuro. La transducción permite predecir estas salidas directamente, uno de los casos particulares de transducción es estimación local [10].

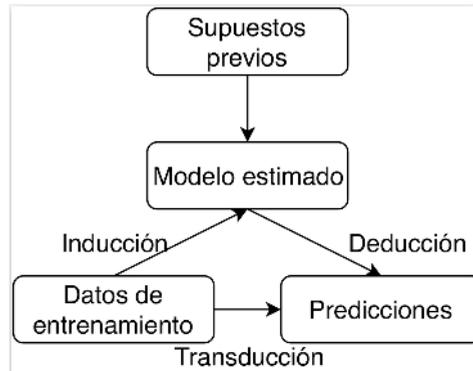


Figura 4.1: Tipos de inferencia: inducción, deducción y transducción.

Los métodos de aprendizaje de datos más comunes, que hacen uso de métodos estadísticos, se pueden agrupar en cuatro clases:

- **Clasificación:** En el problema clásico de dos clases, si la salida del sistema solamente toma dos valores $y = 0, 1$ correspondiendo a cada clase. La función de pérdida que mide el error de clasificación, y que se busca minimizar, está dada por una función compuesta que debe cubrir las dos clases. Se deben usar los datos de entrenamiento para encontrar la función indicadora f que minimiza la probabilidad de un error de clasificación.
- **Regresión:** La regresión debe estimar los valores de una función real basada en un conjunto de datos de entrenamiento. El resultado del sistema en problemas de regresión es una variable aleatoria que toma valores reales, y se interpreta como la suma de una función determinística $g(x)$, la cual es el promedio de de la función condicional de probabilidad.
- **Estimación de densidad:** Para estimar la densidad de x la salida obtenida del proceso de aprendizaje es un conjunto de densidades $\omega \in \Omega$, usando la función de pérdida $L(f(x, \omega)) = -Ln(f(x, \omega))$.

- Agrupamiento (*clustering*): El objetivo es crear un espacio distribuido por los valores x y partirlo de manera óptima en una pre-especificada cantidad de regiones/grupos, de manera que nuevas observaciones se representen en el espacio como un punto y pertenezcan a una de las regiones. Muchas veces es necesario reducir las dimensiones para fijar los centros en el espacio y las observaciones se asignan al grupo con el centro más cercano.

4.4. La estadística en el aprendizaje a máquina

En principio la máquina no necesita intervención humana para aprender, pero elegir el mejor algoritmo para cada problema siempre requiere una parte informal que describa cuáles son las variables de entrada y salida, la representación de los datos y la incorporación de la mayor cantidad de conocimiento previo en el diseño del sistema de aprendizaje de datos [10].

Estos cuatro métodos son todos ampliamente utilizados para resolver problemas de todas las áreas, incluyendo medicina, economía, biología, ingeniería, matemáticas, química y ciencias sociales.

4.4.1. Reducción de dimensión: métodos estadísticos

Debido al problema de las grandes bases de datos se han implementado algunas técnicas para compactar la información llamadas reducción de dimensión. La más popular es PCA (*Principal Component Analysis*) y también existen métodos superficiales y no lineales.

Componentes principales lineales PCA toma un conjunto de datos y los reduce a un par de vectores ortonormales. Se tienen los datos x_i se resumen usando la función de aproximación de la ecuación 4.1. En donde f es una función vectorial, u es el promedio de los datos, V es una matriz con columnas ortonormales.

Entonces cuando se calcula $x_i V$ se obtiene una proyección de baja dimensión de los vectores x_i [10].

$$f(x, V) = u + (xV)V^T \quad (4.1)$$

Curvas y superficies principales Aunque PCA es uno de los métodos más utilizados, es necesario que los datos tengan distribución normal para poder ser aproximados correctamente. Cuando se tienen datos con distribuciones inusuales es conveniente usar otras técnicas. La primera es la *curva principal*, que es una generalización no lineal de PCA, se usa una función vectorial F igual que en el caso anterior pero normalmente se eleva a la potencia 2, no es común elevarla a una potencia superior. Y debe cubrir la condición de que todos los puntos en la curva deben ser el promedio de todos los puntos en esa región.

4.4.2. Aprendizaje supervisado

El campo de aprendizaje a máquina está en crecimiento y se proponen decenas de nuevos algoritmos cada año en las áreas de redes neuronales, sistemas difusos, algoritmos genéticos, procesamiento de señales, etc. En esta sección se dará una introducción a los algoritmos más representativos.

Los primeros son los **algoritmos de clasificación** que buscan encontrar la relación entre las variables observadas y las clases o etiquetas para poder realizar predicciones respecto a la clase a la que pertenecen nuevas observaciones. Se tiene un conjunto de datos de entrenamiento y de prueba. Los algoritmos más populares de clasificación son:

1. **Regresión.** Los métodos de regresión utilizan optimización continua de la función de pérdida. Las dos funciones de pérdida más utilizadas son: error cuadrado y entropía cruzada. Estas funciones aproximan errores de clasificación. La más común es *regresión logística*.
2. **Redes Neuronales.** Usa la función de pérdida de error cuadrado y su única diferencia con regresión que es que utiliza la función de Sigmoid como hipótesis. La

metodología que siguen las redes neuronales es: escalamiento de las variables de entrada (normalmente promedio cero y varianza 1), se suavizan las clases en lugar de $\{1, 0\}$ puede ser $\{0.9, 0.1\}$ que ayuda a acelerar el aprendizaje, se inicializan los pesos de la red, se busca minimizar el error cuadrado y después se minimiza el error de clasificación.

3. **Árboles.** Los árboles también son eficientes algoritmos para clasificación, además de que pueden brindar los patrones que se siguieron para definir las clases y poder tener una interpretación de causalidad entre las observaciones y las clases. Normalmente se usa búsqueda tipo Greedy y la función de costo a minimizar puede ser la de *Gini* o *entropía* y se para la búsqueda al alcanzar el criterio de error de clasificación. Los más populares son *árboles de decisión* y *bosque aleatorio*.

Otro conjunto de algoritmos son los llamados **métodos de regresión**. La regresión estima funciones en el conjunto continuo. Los regresores más comunes son los estimadores lineales que obedecen el principio de superposición, normalmente el estimador es una función compuesta por la combinación lineal de funciones base fijas de aprendizaje. Se define la variable objetivo y las variables independientes $y = \beta X$ en donde y es la variable objetivo, β es el vector de coeficientes y X es la matriz de datos de entrada. Si el vector β cuenta con más de dos coeficientes normalmente se llama *regresión multilineal*.

Un caso particular de regresión es la regresión de panel fija. Ésta toma en cuenta los efectos de series de tiempo y cada individuo queda fijo. Este tipo de regresión es comúnmente utilizada en economía [4]. El modelo que siguen es parecido al anterior

$$y_{it} = \alpha_i + X_{it}'\beta \quad (4.2)$$

En donde el índice i corresponde al individuo y t la serie de tiempo.

Otra técnica algorítmica importante son las **máquinas de vectores de soporte**, o SVM por sus siglas en inglés, son un proceso de aprendizaje estadístico utilizado tanto

para regresión como para clasificación. Utiliza hiperplanos para separar las observaciones en el conjunto de datos de entrenamiento.

$$D(x) = (w \cdot x) + w_0 \quad (4.3)$$

En donde D es la función de decisión, x son los datos de entrenamiento y w_0 , w son los coeficientes a encontrar. Esta formulación permite construir la función de separación usando explícitamente los datos de entrenamiento. SVM se puede utilizar para clasificación y regresión.

En el caso de clasificación se utiliza un método de producto interno del kernel para hacer un mapeo de alta dimensión y después se coloca el hiperplano que separa las clases.

En caso de querer realizar una regresión lineal se utiliza la función,

$$f(x, w) = \sum_{j=1}^m w_j g_j(x) \quad (4.4)$$

En donde g es una función de transformación no lineal y w el conjunto de coeficientes. Se usa una función de pérdida que se minimiza para encontrar la mejor aproximación [10].

El siguiente de esta lista son las **redes neuronales**. Estas retoman los principios del modelo de procesamiento paralelo distribuido (PDP por sus siglas en inglés, *Parallel Distributed Processing*) descrito por Rumelhart, Hinton y McClelland [47] para describir el funcionamiento del cerebro humano. De acuerdo con el modelo PDP, la unidad fundamental de procesamiento es la neurona, capaz de procesar un conjunto de entradas $\mathbf{x} = x_1, x_2, \dots, x_m$ para producir una salida y [32]. Cada entrada es multiplicada por su peso correspondiente w_i . El producto $x_i w_i$ es suministrado a la neurona, para ser sumado con todas las entradas ponderadas y obtener la suma neta $net = x_1 w_1 + x_2 w_2 + \dots + x_m w_m = \mathbf{x} \cdot \mathbf{w}$. Finalmente, la neurona calcula una salida y como una función de net , tal que $y = f(net)$, donde f se conoce como una función de activación; las más comunes son las de tipo escalón, lineales, o sigmoides.

El patrón de conexiones entre neuronas normalmente se conoce como arquitectura. En la práctica, el número de neuronas de entrada y salida depende del problema específico, mientras que el número de capas ocultas no suele ser mayor a dos. La forma

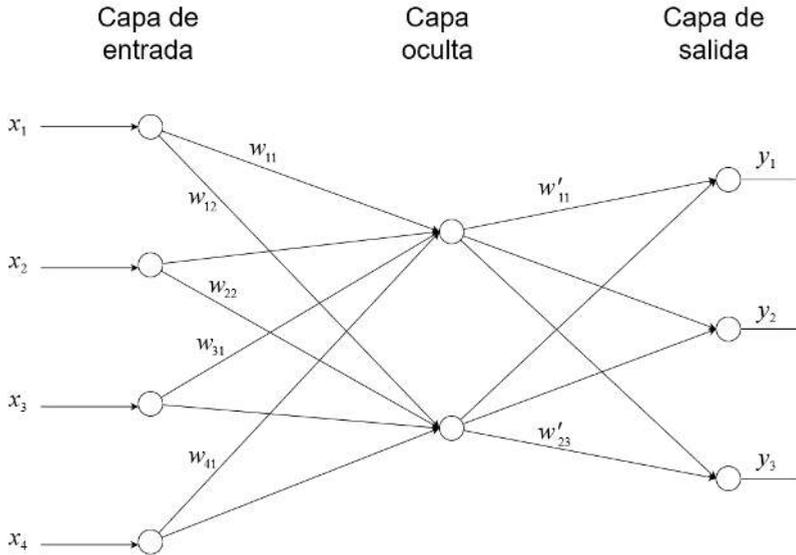
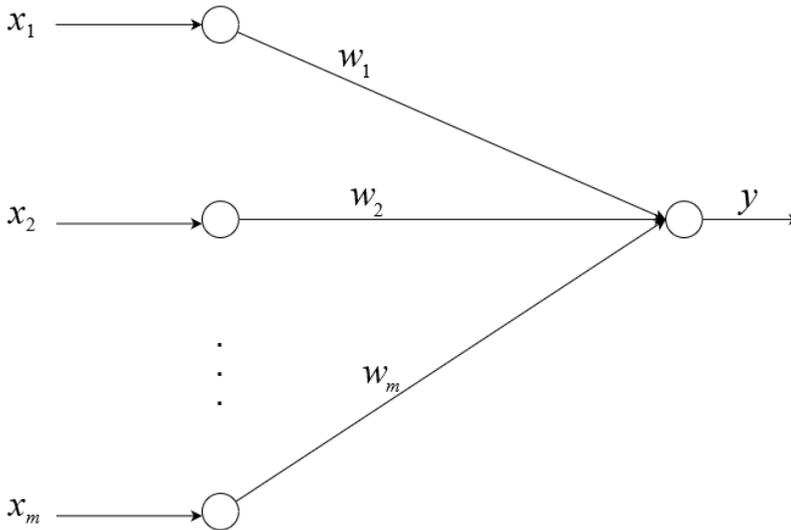


Figura 4.2: Arquitectura simple para una red neuronal multi-capas (sólo algunos pesos son representados).

en que una red neuronal *aprende* es mediante el ajuste gradual de los pesos. Este proceso consiste en la propagación de las entradas hacia adelante dentro de la red (*feedforward*), y la propagación de la corrección del error hacia atrás desde las salidas (*backward propagation*).

El perceptrón es una red neuronal propuesto originalmente por Rosenblatt [46], la cual solo tiene una capa de entrada y una de salida, como se ve en la Figura ?? . Sus aplicaciones son más bien teóricas pues permiten identificar los límites de la representación, es decir si una red neuronal es capaz de producir un resultado específico dados los pesos apropiados.



La regla general de aprendizaje del perceptrón está dada por:

$$\mathbf{w}^{nuevo} = \mathbf{w}^{ant.} + e\mathbf{p} \quad (4.5)$$

$$b^{nuevo} = b^{ant.} + e \quad (4.6)$$

donde $e = t - a$ es el error calculado como la diferencia entre el valor esperado t y el calculado a , b es el sesgo introducido al perceptrón, y \mathbf{p} es el patrón de entrada.

4.4.3. Aprendizaje no supervisado

El problema de aprendizaje no supervisado puede verse como la tarea de descubrir una distribución probabilística que describa los datos [19]. Entonces, asumiendo que los datos con los cuales se genera el modelo \mathcal{D} son independientes e idénticamente distribuidos, el conocimiento de los modelos estará dado por

$$P(m|\mathcal{D}) = \frac{P(m)P(\mathcal{D}|m)}{P(\mathcal{D})} \propto P(m) \prod_{n=1}^N P(x_n|m) \quad (4.7)$$

De la misma forma, las predicciones del modelo para nuevas instancias se aproximan con,

$$P(x|\mathcal{D}) = \sum_{m=1}^M P(x|m)P(m|\mathcal{D}) \quad (4.8)$$

Ejemplos de técnicas de aprendizaje supervisado son comunes en las tareas de reducción de dimensiones (descritos en la Sección 4.4.1) y el agrupamiento, el cual busca establecer grupos entre los datos identificando la similitud entre ellos. Aunque la pregunta persiste sobre si los datos realmente poseen la estructura encontrada por los algoritmos o los grupos son más bien impuestos, se pueden identificar dos tipos de métodos:

- **Agrupamiento por particiones.** El objetivo es obtener una partición de los datos por medio de la optimización de una función de similitud. Ésta puede ser basada en la reducción del error cuadrático, como el algoritmo *k-means* el cual minimiza la distancia entre cada punto y el centroide del grupo. También puede estar basado en medidas de densidad donde se considera la vecindad de cada elemento; un ejemplo es el algoritmo DBSCAN. Por otro lado, existen los métodos de resolución de mezclas que asumen que los datos provienen de varias distribuciones, por lo que se intentan estimar los parámetros de éstas.
- **Agrupamiento jerárquico.** Estos métodos buscan obtener una jerarquía, llamada dendograma, que muestre las relaciones entre los grupos. Los grupos pueden ser encontrados al acumular los grupos pequeños dentro de otros más grandes, conocidos como algoritmos aglomerativos, o al separar los grupos más grandes, conocidos como algoritmos divisivos. De esta forma, la partición de los datos se encuentra al cortar el dendograma en el punto deseado [20].

4.4.4. Evaluación de los métodos de aprendizaje de máquina

Una parte importante del proceso de aprendizaje automático es la evaluación, pues permite saber qué tan bien fueron *aprendidos* los patrones por el modelo. La motivación principal de este tipo de análisis es probar la capacidad de generalización del modelo, por lo cual se emplean métodos estadísticos en conjunto con suposiciones de la distribución de los datos para descubrir el vínculo que existe entre la exactitud sobre los datos disponibles y la *verdadera* exactitud sobre la distribución total de los datos [31].

Para esto se puede diferenciar el error de la muestra del error real, pues el primero considera la diferencia de la hipótesis (o valor predicho) contra el valor objetivo (o valor observado), y el error verdadero es la probabilidad de que una instancia obtenida aleatoriamente de una distribución \mathcal{D} sea clasificada incorrectamente. El cálculo de estos error se encuentra dado por:

$$error_S(h) \equiv \frac{1}{n} \sum_{x \in S} \delta(f(x), b(x)) \quad (4.9)$$

$$error_{\mathcal{D}}(h) \equiv \Pr_{x \in \mathcal{D}}[f(x) \neq b(x)] \quad (4.10)$$

donde n es el número de muestras en S , $\delta(f(x), b(x))$ es 1 si $f(x) \neq b(x)$ y 0 en el caso contrario, y $\Pr_{x \in \mathcal{D}}$ denota que la probabilidad de la instancia es obtenida de la distribución \mathcal{D}

Un concepto asociado a la medida de incertidumbre sobre el error es el intervalo de confianza $N\%$, que puede ser entendido como un intervalo para algún parámetro p en el cual se espera encontrar p con probabilidad $N\%$. En el mismo sentido, el teorema del límite central retoma importancia pues permite aproximar las distribuciones que gobiernan los valores de una muestra a una distribución Normal para n suficientemente grandes (se acostumbra $n \geq 30$).

Estos conceptos son fácilmente aplicados al cálculo del desempeño de un clasificador, y se puede encontrar el error de conteo al simplificar la Ec. 4.9

$$error(D) = \frac{N_{error}}{N_t} \quad (4.11)$$

donde D es el clasificador que se está evaluando, N_{error} es el número de elementos clasificados erróneamente, y N_t es el número total de elementos en el conjunto de datos donde se probó D . Entonces, por el teorema del límite central, y asumiendo que la probabilidad de que D cometa un error está dada por $P_D = error(D) = N_{error}/N_t$, el intervalo de confianza con nivel de confianza igual a 95 % para el error es:

$$\left[\hat{P}_D - 1.96 \sqrt{\frac{\hat{P}_D(1 - \hat{P}_D)}{N_t}}, \quad \hat{P}_D + 1.96 \sqrt{\frac{\hat{P}_D(1 - \hat{P}_D)}{N_t}} \right] \quad (4.12)$$

Otra herramienta que permite identificar en qué clases se encuentran los errores son las **matrices de confusión**. Éstas consideran el número de elementos bien y mal clasificados al aplicar D sobre el conjunto de datos \mathbf{Z}_t con N instancias. Considerando un ejemplo en donde sólo existan dos clases $\{\omega_+, \omega_-\}$, la matriz de confusión sería como en la tabla 4.1: Donde TP es el número de verdaderos positivos, es decir los casos

ω_+	TP	FN
ω_-	FP	TN

Tabla 4.1: Matriz de confusión para un problema con dos clases

que pertenecen a la clase ω_+ y fueron clasificados como tal. De igual forma, TN es el número de verdaderos negativos. FN y FP es el número de falsos negativos y positivos, respectivamente, que contabiliza el número de elementos que fueron mal clasificados.

Posteriormente se puede comparar dos algoritmos de clasificación y determinar si esta diferencia es significativa estadísticamente. El primer paso consiste en hacer experimentos con los modelos a comparar haciendo uso de un gran número de datos diferentes, tanto reales como simulados.

Existen varias métricas que proponen comparar el número de objetos clasificados erróneamente por los métodos en cuestión, y que se basan en pruebas de hipótesis para encontrar la significancia dado el nivel de confianza. Entre ellos se encuentran la prueba de McNemar, diferencia de proporciones, la prueba Q de Cochran, y la prueba F [25].

Finalmente se realiza un análisis de los resultados de clasificación son retomadas principalmente del campo de la recuperación de información (*Information Retrieval*, IR), la psicología o el análisis de señales, y consideran la tasa de instancias clasificados correcta e incorrectamente. De esta forma el objetivo de la exhaustividad, también conocido como sensibilidad o tasa de positivos reales ($tpr = TP / (TP + FN)$), es identificar los casos positivos reales. En cambio, la precisión considera los casos que fueron clasificados de manera correcta con respecto al total de instancias en esa clase ($TP / (TP + FN)$).

La exactitud es la medida de cuántos objetos fueron clasificados correctamente sin importar la clase a la que pertenecen ($(TP + TN) / N$), y es una métrica muy popular en el aprendizaje automático. Por el contrario, la proporción en que los elementos de una clase sean clasificados erróneamente resulta conveniente al analizar el desempeño global del modelo, y se conoce como tasa de falsos positivos ($fpr = FP / (FP + FN)$).

El análisis ROC (*Receiver Operating Characteristics*) permite una visualización más clara de la relación entre tpr y fpr y su susceptibilidad al sesgo. De esta forma es posible identificar un clasificador con mejor desempeño que otro gráficamente al comparar el área bajo la curva (AUC) ROC [38].

4.5. ¿Cómo representar el conocimiento?

En la mayoría de los problemas de análisis estadístico se requiere representar el conocimiento de manera que pueda ser operado computacionalmente y debe almacenarse en forma de datos, a los cuales se pueda acceder desde diferentes lugares y por todo tipo de usuarios, de manera que la información esté disponible.

En principio el conocimiento debe tener una representación numérica (enteros, reales o complejos), categórica o cadenas de caracteres. En la buena práctica de limpieza y almacenamiento de datos debe haber un valor por celda, una observación por fila y una variable por columna. Sin embargo, en la práctica se sabe que más del 80 % de los datos generados están desestructurados. Es por eso por lo que es importante contar con poderosas herramientas de almacenamiento de datos que permitan manejar grandes cantidades de información, realizar lectura, escritura y posiblemente limpieza de manera eficiente.

1. **Hadoop.** Con su herramienta *Hadoop Distributed File System*, debido a su gran capacidad de paralelización permite guardar grandes bases de datos y es rápidamente replicable en el *cluster* que el usuario necesita lo cual permite que la información esté disponible todo el tiempo en miles de dispositivos a la vez [21].
2. **SQL/NoSQL.** De las siglas en inglés *Structured Query Language*, es un lenguaje de programación que gestiona bases de datos relacionales y existen diferentes herramientas que lo soportan como *Hive*, *Presto*, *MySQL*, *SQL Server*. Aunque también existe la versión no estructurada (*Not only SQL*) que permite manejar datos no estructurados. Y también existen herramientas libres que soportan No-SQL como *PolyBase* que corre sobre *SQL Server* con acceso a *Hadoop* para datos estructurados y no estructurados [33, 30].
3. **Excel.** Es una de las herramientas más populares para almacenamiento de datos sobre todo a nivel industrial. Es posible conectarla a *Hadoop* para acceder a bases de datos y realizar operaciones básicas en los datos de limpieza y visualización. También es posible utilizarla con *Microsoft HDInsight* que es la base de datos de *Microsoft* operada por *Hadoop* y permite guardar y manejar datos en la nube (*Azure*) [3].

También existen bases de datos públicas como *Kaggle* que libera grandes cantidades de información con la finalidad de esparcir el conocimiento y permitir a la comunidad

de ciencia de datos acceder a mediciones de alta calidad con la cual pueden aplicarse técnicas de limpieza, análisis, entrenamiento y predicción. Incluso se realizan concursos en donde los usuarios deben construir el modelo con las mejores predicciones, muchas veces se llevan a cabo en dos estaciones, para que los usuarios entrenen su modelo sin conocer los datos finales de prueba. Estas competencias son reconocidas por toda la comunidad de ciencia de datos y aprendizaje a máquina a nivel mundial [24].

4.6. Herramientas para análisis estadístico y visualización de datos

Actualmente en mercado requiere cada vez más y mejores analistas que estén entrenados en matemáticas aplicadas y programación para poder tener ventajas competitivas sobre sus bases de datos y la información disponible en internet.

Esto ha ayudado al desarrollo de más y mejores herramientas en el mercado, deben contar con capacidad de paralelización para procesamiento de grandes bases de datos y poderosas librerías de gráficos para poder comunicar los descubrimientos obtenidos con los datos utilizados. En esta sección presentamos las herramientas más populares al momento y sus diferentes ventajas.

1. **R.** Esta herramienta es un lenguaje de programación desarrollado desde un principio para estadística antes llamado *S*. Permite el diseño de experimentos de alta complejidad, la lectura de grandes bases de datos por su capacidad de paralelización. También cuenta con la librería `ggplot2` para graficación de alta calidad y diseño. Cuenta con más de 11,500 paqueterías de análisis y funciona en todos los sistemas operativos [39].
2. **Python.** Es uno de los lenguajes de programación más populares actualmente, está orientado a objetos y es fácil de leer, escribir y mantener por ser libre y gratuito. Además de que también es paralelizable, cuenta con poderosas librerías de

4.6. HERRAMIENTAS PARA ANÁLISIS ESTADÍSTICO Y VISUALIZACIÓN DE DATOS

análisis de datos como *pandas*, *scikitlearn*, *theano*, *tensorflow* y *keras*. Además de *matplotlib* para visualización que tiene varias paqueterías dinámicas [40].

3. **Tableau.** Es un software creado especialmente para resolver problemas de negocios de forma interactiva, puede compartirse en redes sociales y directamente con clientes. Cuenta con un lenguaje visual de bases de datos llamada VixQL y puede emparejarse con hojas de cálculo e información web en tiempo real, haciendo la actualización de información fácil de visualizar con animaciones dinámicas [52].
4. **SAS.** De sus siglas en inglés *Statistical Analysis System*, es un programa licenciado independiente con más de 200 componentes de análisis, entre los que se pueden llevar a cabo análisis estadísticos (STAT), gráficos y representaciones (GRAPH), investigación de operaciones (OR), series de tiempo y economía (ETS), análisis clínicos (PH), minería de datos (Miner), entre otros. Es una de las empresas líderes en productos de análisis con más del 30 % del mercado en 2013. Ha tenido grandes avances en análisis de información de redes sociales y en la nube[48].
5. **Spark.** *Apache Spark* es un software libre creado por la Universidad de California en *Berkeley* y se creó para la implementación de técnicas de ciencia de datos y aprendizaje a máquina en los centros de cómputo *Hadoop*, que permite paralelizar implícitamente los procesos y hacerlos hasta 100 veces más rápido. Puede manejar APIs en R, Python, Java y Scala. Cuenta con varias librerías como Spark SQL para procesar datos estructurados en SQL, MLlib para implementación de algoritmos de *Machine Learning* y *GraphX* para visualización [50].
6. **Excel.** Es la herramienta de análisis más utilizada y popular. Es el estándar de las hojas de cálculo a nivel mundial, independientemente del lenguaje de programación que cada programador domina Excel brinda una interfaz básica de visualización de datos, almacenamiento, filtración y graficación. Soportado por

todos los sistemas operativos permite la fácil visualización de tablas, aplicación de fórmulas, creación de grafos y compartir archivos en la nube [15].

7. **Rapidminer.** Es una de las herramientas más fáciles de utilizar debido a que no requiere programación en *script*. Puede leer datos de Excel, MySQL, Oracle, IBM DB2, SPSS, Sybase, etc. También facilita la tarea de minería y limpieza de datos. Cuenta con varias librerías de aprendizaje a máquina y predicción, además de que cuenta con varias opciones de visualización. Es eficiente para el análisis de texto y se tiene control sobre los formatos de los datos que se analizan [42].

8. **Weka.** Es una herramienta libre con una amplia gama de algoritmos de aprendizaje a máquina implementados. Los desarrolladores pueden implementar su algoritmo en JAVA e incluirlo a las paqueterías de Weka. Incluye paqueterías de limpieza de datos, preparación, clasificación, regresión y visualización. Algunos de los algoritmos son paralelizables y pueden llamarse desde línea de comandos. Pero en principio no es necesario conocer ningún lenguaje de programación para ser capaz de usarlo [56].

9. **Matlab.** Nombre abreviado de *Matrix Laboratory* es un poderoso lenguaje de programación muy utilizado en áreas de ciencias e ingeniería por sus poderosas rutinas matriciales que permiten vectorizar operaciones complicadas. En los últimos años han desarrollado paqueterías especializadas para procesamiento de lenguaje natural, ciencia de datos, aprendizaje a máquina, estadística, procesamiento de señales de audio e imágenes, finanzas, biología y la paquetería *Simulink* que permite realizar simulaciones para pruebas y verificación de modelos de diferentes áreas. Es un software licenciado, pero se ha desarrollado la versión libre llamada *Octave* [28, 35].

4.7. Trabajos relacionados

Respecto al surgimiento del concepto de *Big Data*, el trabajo de Fan [16] presenta los retos y metas del análisis masivo de datos. Entre los que se trata de desarrollar mejores modelos predictivos y encontrar patrones que respondan a preguntas de investigación. Sin embargo, los retos que presentan estas bases de datos que agrupan todo tipo de información nunca habían sido tratados antes, esa área de oportunidad está siendo exitosamente tratada con métodos estadísticos, el tratamiento de datos faltantes, ruido, correlaciones, endogeneidad. Se introducen los métodos de reducción de dimensión con PCA (*Principal Component Analysis*) y optimización con LLA (*Local Linear Approximation*). También se explica la herramienta Hadoop que permite la distribución de las tareas con servidores remotos. De esta manera quedan muchas tareas que se buscan resolver con métodos estadísticos en el futuro.

Una aplicación más concreta es el uso de la herramienta R para el análisis de la respuesta a dosis de parte del Departamento de Nutrición de la Universidad de *Copenhagen* [44]. Los modelos de respuesta a dosis suelen ser modelos de regresión en donde la variable independiente es la concentración y la variable dependiente es la respuesta o efecto, que comúnmente es una variable discreta que representa presencia o ausencia de síntomas. Para lo cual se construye un modelo logístico con una estructura jerárquica, se calculan mínimos cuadrados y se estima la máxima similitud. Finalmente se lleva a cabo una regresión inversa para calcular las dosis que darán mejores resultados. Estos cálculos pueden realizarse en líneas de código que permiten a los investigadores hacer su trabajo reproducible y eficiente, así como transferible a otros trabajos similares.

Otro ejemplo de avances recientes que se han logrado a partir de escalar métodos estadísticos y la mejora del poder computacional es la construcción de modelos de permutación que permiten controlar con exactitud la presencia de falsos positivos en el análisis de imágenes neuronales. Utilizando regresión múltiple, inferencia, aleatoriedad y modelos lineales generalizados *Winkler* de la Escuela de Medicina de *Yale* [57] pre-

senta una metodología experimental que permite estructurar resultados que ayudan a mejorar las evaluaciones a imágenes cerebrales computacionalmente.

Genética es una de las áreas en donde el manejo masivo de datos se vuelve crucial, ya que se buscan patrones e inconsistencias en cadenas de información con un total de más de 3 miles de millones de pares base al analizar el genoma humano. En un trabajo de *Nature* por la Universidad de California Berkeley en donde se unen el Departamento de Estadística, Biología Molecular y Neurociencia [43], se utiliza la herramienta estadística R para encontrar cambios en dobleces en cadenas de ARN. Llevando a cabo técnicas de normalización para minimizar los efectos de diferencias en profundidad de lectura de cada secuencia y tener lecturas uniformes para analizar. Esta metodología no es transferible pero muestra avances en el control del análisis de muestras de ARN.

La distribución de la electricidad es un problema interesante ya que se busca construir una red inteligente que genere solamente la cantidad de electricidad que será utilizada para que la distribución sea suficiente y precisa, en el trabajo de Jurado [23] se compararon cuatro técnicas de aprendizaje automático para solucionar el problema: bosque aleatorio, redes neuronales, razonamiento inductivo difuso y promedio móvil integrado auto-regresivo. La modelación con razonamiento difuso da las mejores predicciones que puede lidiar con diferentes edificios, patrones de consumo, horarios de trabajo y factores climatológicos.

El aprendizaje estadístico tiene principal importancia en automatización de procesos que pueden abarcar física, fenómenos sociales, diseño ingenieril, descubrimiento de medicamentos, sistemas ecológicos, diseño de software, entre otros. La automatización tiene que ver con la correcta aplicación de métodos estadísticos para la aplicación de optimización bayesiana que minimizará el uso de recursos para resolver problemas como sistemas de recomendación en tiendas on-line, mejorar la visión en robots autómatas, reducir la cantidad de sensores de calor en edificios inteligentes. El algoritmo de optimización Bayesiana permite combinar espacios de búsqueda con variables continuas y categóricas. Los modelos que normalmente se aplican son: muestreo Thompson, regre-

siones lineales generalizadas, modelos no paramétricos, espectros gaussianos y bosque aleatorio. En un trabajo presentado por Adams, Freitas [49] que trabajan como líderes de investigación en Twitter y Google respectivamente además de ser profesores de Harvard y Oxford explican el resurgimiento de los sistemas Bayesianos para aprovechar los nuevos modelos computacionales de manera óptima en las aplicaciones mencionadas anteriormente.

El área de la medicina ha visto una gran área de oportunidad en el análisis conjunto de datos que tienen que ver con el área administrativa, clínica, historiales de pacientes, mediciones biométricas, reportes de pacientes, imagenología y análisis clínicos para mejorar la experiencia de los pacientes particularmente en el tratamiento de enfermedades cardiovasculares [8]. Algunos algoritmos predictivos permiten identificar pacientes de alto riesgo, sin embargo, las enfermedades cardiovasculares son muy heterogéneas en el sentido de que los síntomas que cada paciente presenta y las deficiencias que puede tener suelen ser muy variados. Es por eso que el *Big data* es una oportunidad para analizar una gran variedad de casos y ayudar al equipo clínico a identificar los mejores tratamientos, ya que estas enfermedades presentan un muy alto costo al sistema de salud pública a nivel mundial.

Aunque todas estas soluciones son muy prometedoras y la comunidad computacional está creciendo ampliamente, en un artículo de la revista *Science* se revisan diferentes trabajos de sectores públicos de salud, seguridad y criminalidad que se han tratado de resolver son algoritmos de aprendizaje a máquina supervisado, y muestra que no debe confundirse la capacidad de predicción de un algoritmo con la toma final de decisiones [2]. Se habla de muchas variables que no pueden representarse en bases de datos e influye en el momento en que debe tomarse una decisión. Por ejemplo, para operar a un paciente de la cadera se pueden analizar sus síntomas y predecir si necesitará una cirugía, sin embargo, es posible que otras enfermedades o una avanzada edad influyan en que la operación resulte más riesgosa y dolorosa que beneficiosa para el paciente. Así existen muchos ejemplos de trabajos en los cuales no se deben olvidar los métodos

empíricos que ayudan a los profesionales a tomar decisiones con información que los algoritmos de aprendizaje no pueden acceder.

Pero la mejora de los sistemas es inminente y la imagenología de materiales atómicos es una de ellas. En los últimos años se ha incrementado la búsqueda de mejores materiales que sean inteligentes y menos contaminantes. Para que estos materiales puedan ser descubiertos y utilizados normalmente se utilizan microscopios electrónicos, la calidad de los microscopios ha incrementado pero las estructuras atómicas siempre han tenido que ser reconstruidas computacionalmente para poder ser interpretadas por los científicos. Ya que no solamente se busca conocer la estructura del material sino también su respuesta a humedad, luz, temperatura, corriente eléctrica, impactos mecánicos, entre otros. Las imágenes electrónicas deben ser comparadas con una gran cantidad de bases de datos de materiales ya conocidos que pueden tener características parecidas. En el trabajo de Belianinov [5] se muestra el uso de reducción de dimensiones con PCA (*principal component analysis*), separación (de-mixing) Bayesiana, agrupamiento y redes neuronales para analizar imágenes de materiales atómicos y extraer sus diferentes características físicas.

Normalmente en las aplicaciones que se han mencionado se trata de encontrar una predicción de una variable observable en base al análisis estadístico de varios parámetros. Sin embargo, también existe la posibilidad de resolver problemas estadísticos inversos. Estos problemas tratan de deconstruir los parámetros del experimento en base al resultado observado. Este enfoque se aplica a resolver el problema de *Ising* utilizando técnicas de ciencia de datos. El problema de *Ising* es un problema de física estadística que trata de modelar transiciones de fase en materiales ferromagnéticos. Otra aplicación es el análisis de actividad neuronal, ya que la identificación de neuronas activas suele ser difícil ya que en el cerebro existen más de 80 mil millones de neuronas. Para la neurociencia es importante conocer los patrones de comportamiento cerebral y esto puede hacerse a partir de una distribución de entropía máxima, usando modelos de regresión lineal generalizada, correlación, paridad y máxima similitud [34].

4.8. Investigación en México

Si bien es cierto que el auge de la ciencia de datos da pie a la investigación en el campo de la inferencia estadística, ésta no se centra únicamente en las aplicaciones metodológicas que se emplean para el análisis de datos. Un área ampliamente estudiada es la formación del razonamiento estadístico como parte de los objetivos educativos en el nivel superior. Al respecto, Tobías-Lara y Gómez-Blancarte [53] discuten sobre la enseñanza de la inferencia estadística, principalmente haciendo una crítica a que este tópico se imparte generalmente de manera aislada sin considerar las estrechas relaciones que mantiene con el análisis exploratorio de datos así como la determinación de marcos de investigación y diseño de experimentos. Como parte de su investigación, las autoras rescatan la necesidad de redefinir la concepción actual sobre el razonamiento inferencial formal e informal, para que de manera integral se consideren los hechos y el contexto (conocimiento del dominio) en el que se encuentran los datos. De esta forma se busca que los alumnos puedan dar argumentos sólidos y derivar conclusiones adecuadas basadas en la completa inferencia estadística.

En el campo de la inferencia estadística, la investigación a cargo de Bowaters en la Universidad de las Américas [6] hace un análisis del enfoque de inferencia fiducial. En el documento se recalca la naturaleza subjetiva del método, pues aunque tiene interpretaciones frecuentistas y Bayesianas, se toma en cuenta el argumento estándar fiducial donde se asumen pivotes como variables primarias aleatorias. El análisis realizado está basado en la respuesta a las críticas más reconocidas contra el argumento fiducial, mencionando casos donde es incluso superior al acercamiento Bayesiano. Es por esto que entendimiento completo de la naturaleza compleja de la inferencia estadística permite aplicar las herramientas que se adecuan mejor a los detalles específicos del problema, y por ende brindar un mejor análisis.

Siguiendo la misma línea de investigación sobre los métodos de inferencia estadística, Bowaters y Gusmán-Pantoja [7] de la Universidad Tecnológica de la Mixteca, realizan una propuesta sobre un método de inferencia híbrido para los casos con valores

especiales de parámetro, esto quiere decir que existe una creencia previa sólida de que el parámetro se encuentra en un intervalo dado. En este sentido, se desarrolla un método híbrido que utiliza los valores de p unilaterales, de manera similar otro método en el que utilizan los valores Q (similares a los valores p bilaterales cuando $\mu_* = \mu_0$) para pruebas de significancia).

En el sector industrial, el control de calidad debe incluir el ciclo de vida del producto. Es por eso que las pruebas vida aceleradas resultan fundamentales para identificar las variables de aceleración que influyen en el desgaste del producto. La estimación de máxima verosimilitud (MLE) e inferencia Bayesiana son los métodos más empleados para analizar las relaciones entre las variables aceleradas. Rodríguez-Picón y Flores-Ochoa [45] abordan el tema, y estudian la aplicación de un modelo general logarítmico lineal que utiliza la distribución logarítmica normal para determinar el efecto del voltaje y la temperatura en un resistor de película de carbono. En el estudio se utiliza el lenguaje estadístico R para implementar el modelo y hacer las estimaciones usando el método de Newton-Raphson. El modelo desarrollado se beneficia del acercamiento Bayesiano cuando hay datos faltantes, y en general disminuye la incertidumbre que devienen de considerar múltiples desgastes o esquemas de estimación.

El análisis de variables críticas para la calidad de los productos es un área de oportunidad para el estudio y aplicación de métodos que permitan analizar y optimizar los procesos industriales de fabricación. Al respecto, De León-Delgado et al. [13] aplican un análisis estadístico multivariable en una red neuronal con función de base radial que considera la significancia estadística entre variables dependientes e independientes, para verificar la correlación entre ellas y corroborar que las suposiciones de análisis son correctas. El estudio se enfoca en el proceso de fundición de molde permanente, en el cual se analizan 3 variables de entrada: temperatura del metal, temperatura del molde e inclinación, y 3 variables de respuesta (dos secciones transversales y el peso). Entre éstas se calculan los coeficientes de *Pearson* y de *Kendall* para determinar la correlación entre las 3 variables de salida; los índices encontrados son concluyentes para determinar

un análisis de varianza multivariable (MANOVA). En la implementación se utilizó un algoritmo genético para especificar los centros de las funciones radiales sobre las cuales se basaría la red neuronal. Con estos parámetros se determinó que el factor más importante en el proceso de fundición es la temperatura del molde. Sin duda, la contribución más importante es la incorporación del análisis estadístico en el proceso de modelación de la red neuronal.

El campo de la genética requiere el análisis información de miles, incluso decenas de miles de genes que codifican información de interés para determinar rasgos característicos de un individuo o población. Este proceso de caracterización genética fue aplicado a *Amblyomma mixtum*, una especie de garrapata común en el ganado, analizando muestras de ARN mitocondrial de especímenes extraídos en la zona costera del Golfo de México [1]. El estudio tiene como finalidad analizar la estructura genética de la especie, y determinar halotipos recurrentes en diferentes poblaciones (determinadas geográficamente). Esta determinación se efectúa mediante pruebas de neutralidad y pruebas de hipótesis, que requieren un análisis de significancia estadística.

No cabe duda de que la estadística es una herramienta fundamental en las tareas que implica la labor científica, no importa cuál sea el área de especialización. En las ciencias sociales, su principal uso se encuentra en el análisis de resultados para derivar conclusiones sobre algún aspecto específico del estudio y su correlación los factores involucrados. Por ejemplo, se ha demostrado la utilidad de los métodos Bayesianos en el desarrollo, evaluación y aplicación de modelos psicológicos empleados en el análisis experimental del comportamiento [54]. Como parte del estudio se demuestra cómo hacer inferencia sobre parámetros que representan variables psicológicas, y cómo se adecuan y comparan los modelos, al mismo tiempo de permitir una representación gráfica que posibilita plasmar las relaciones jerárquicas y causales de los modelos de comportamiento más complejos. Este caso de estudio expone cómo las propiedades estadísticas de los métodos Bayesianos facilita la tarea de realizar pruebas de hipótesis y teorías que per-

mitan un desarrollo creativo y exploratorio hacia el desarrollo de nuevos modelos de comportamiento.

En un estudio conjunto de la Universidad Autónoma de Baja California y la Universidad Autónoma de Sinaloa [41] se desarrolló un sistema de tutor inteligente (ITS) que emplea una técnica de inferencia de conocimiento de alumno basado en redes Bayesianas. Este método permite una rápida identificación de los temas dominados por el alumno para determinar los siguientes temas a abordar. El sistema obtuvo un 75.6% de precisión en la inferencia del conocimiento, y sirve como módulo de evaluación para identificar conceptos conocidos o desconocidos por el alumno. Con este método es posible implementar exámenes adaptados al conocimiento del alumno, es decir que la dificultad de las preguntas se determina de acuerdo al nivel de conocimiento del estudiante. También resulta una herramienta muy útil en el desarrollo y adaptación de materiales de enseñanza que se integran de manera automática en el ITS.

En la investigación sobre hallazgos cerámicos en la zona arqueológica en Xalasco, Tlaxcala, México, [27] se desarrolló un método basado en pruebas estadísticas para identificar grupos químicos y determinar patrones en los datos así como valores atípicos. La metodología de análisis propuesta se realizó en el entorno estadístico R, haciendo uso de los paquetes *compositions* y *RobCompositions*. Adicionalmente, para la clasificación de las muestras se utilizaron las herramientas disponibles en Matlab.

Los datos de la composición química obtenidos mediante espectrometría de rayos X (ED-XRF) son primeramente preprocesados mediante transformación de razón logarítmica centrada (CLR), la cual utiliza una partición binaria secuencial (SBP) basada en conocimiento a priori para construir las coordenadas de los datos transformados. Posteriormente, para separar los datos en dos clases se utilizó el análisis de discriminante de mínimos cuadrados parcial (PLS-DA). Dividiendo las observaciones de manera estratificada y utilizando la técnica de validación cruzada se obtuvo una tasa de error de 0.06 y área bajo la curva ROC de 0.99. Los métodos de T^2 de Hotelling y el análisis de residuos se aplicaron para identificar los valores atípicos de cada clase. Con la infor-

mación recabada se construyó un dendograma CoDA que facilita la interpretación de los resultados e identificación de elementos con mayor concentración, lo cual sugiere la existencia de dos recetas de manufactura de cerámica en la zona.

En los procesos electorales es de interés tener una estimación adecuada del conteo de votos el mismo día que lleva a cabo la elección, esto con el fin de anticipar los resultados y poder darlos a conocer a los medios de comunicación, partidos políticos, así como autoridades y organizaciones interesadas. En México, este procedimiento se conoce como *conteo rápido* y está a cargo del Instituto Nacional Electoral (INE). En las elecciones de 2006 y 2012, un método de inferencia Bayesiana permitió predecir el resultado de las elecciones, incluso cuando en el primer caso la diferencia entre los dos candidatos líderes fue sólo de 6.2 %. El método propuesto [29] requiere el conteo final de una muestra aleatoria de casillas de votación, y su simplicidad permite una rápida ejecución del modelo, lo que permite predecir resultados confiables antes de la media noche, como es requerido por el INE.

4.9. Conclusiones

En este capítulo se explicó el surgimiento de la estadística como la ciencia que ha influido en la toma de decisiones en la historia de la humanidad desde el siglo XVII aproximadamente. Y cómo ahora, a partir del descubrimiento internet y el aumento del poder computacional ha cobrado especial importancia en el diseño de modelos de predicción y técnicas de exploración, análisis y validación de información.

También presentamos la relación que tiene la estadística con la probabilidad y la computación, particularmente con la ciencia de datos, el aprendizaje a máquina y con la evaluación de modelos. Y aunque se mencionaron decenas de ejemplos de algoritmos que se utilizan actualmente para modelación y de herramientas que han implementado los métodos estadísticos más utilizados, sabemos que cada año se proponen nuevas técnicas que se van adaptando a los problemas que se necesitan resolver.

En los últimos años la estadística se ha utilizado para resolver problemas relacionados con medicina, imagenología, genética, ingeniería, optimización, servicios y materiales. Especialmente en México se está trabajando en inferencia estadística, control de calidad, biología, psicología, educación y arqueología.

Con esta gran variedad de áreas utilizando técnicas estadísticas, creemos que la estadística junto con la computación se han ido convirtiendo en áreas de conocimiento indispensables para desarrollar cualquier ciencia. Este nuevo pilar en la especialización de los científicos actuales va a permitir desarrollar un lenguaje común que permita unificar el conocimiento y abrir el diálogo a una mayor colaboración e internacionalización de la ciencia.

Bibliografía

- [1] Mariel Aguilar-Domínguez, Sokani Sánchez-Montes, María Dolores Esteve-Gassent, Carolina Barrientos-Salcedo, Adalberto Pérez de León, and Dora Romero-Salas. Genetic structure analysis of *amblyomma mixtum* populations in veracruz state, mexico. *Ticks and Tick-borne Diseases*, 10(1):86 – 92, 2019. ISSN 1877-959X. doi: <https://doi.org/10.1016/j.ttbdis.2018.09.004>. URL <http://www.sciencedirect.com/science/article/pii/S1877959X18301407>.
- [2] S. Athey. Beyond prediction: Using big data for policy problems. *Science*, 355 (6324):483–485, 2017. URL www.scopus.com. Cited By :46.
- [3] Azure. Microsoft azure: plataforma y servicios de informática en la nube. URL <https://azure.microsoft.com/es-es/>.
- [4] Badi H. Baltagi. *Econometric analysis of panel data*. John Wiley & Sons, Inc., 2016.

- [5] A. Belianinov, R. Vasudevan, E. Strelcov, C. Steed, S. M. Yang, A. Tselev, S. Jesse, M. Biegalski, G. Shipman, C. Symons, A. Borisevich, R. Archibald, and S. Kalinin. Big data and deep data in scanning and electron microscopies: deriving functionality from multidimensional data sets. *Advanced Structural and Chemical Imaging*, 1(1), 2015. URL www.scopus.com. Cited By :45.
- [6] Russell Bowater. A defence of subjective fiducial inference. *AStA Advances in Statistical Analysis*, 101, 01 2017. doi: 10.1007/s10182-016-0285-9.
- [7] Russell J. Bowater and Ludmila E. Guzmán-Pantoja. Bayesian, classical and hybrid methods of inference when one parameter value is special, 2018.
- [8] E. T. Bradlow, M. Gangwar, P. Kopalle, and S. Voleti. The role of big data and predictive analytics in retailing. *Journal of Retailing*, 93(1):79–95, 2017. URL www.scopus.com. Cited By :46.
- [9] Stefano Ceri. On the role of statistics in the era of big data: A computer science perspective. *Statistics & Probability Letters*, 136:68 – 72, 2018. ISSN 0167-7152. doi: <https://doi.org/10.1016/j.spl.2018.02.019>. URL <http://www.sciencedirect.com/science/article/pii/S0167715218300646>. The role of Statistics in the era of big data.
- [10] Vladimir Cherkassky and Filip Mulier. *Learning from data: concepts, theory, and methods*. Wiley, 2007.
- [11] George W. Cobb and David S. Moore. Mathematics, statistics, and teaching. *The American Mathematical Monthly*, 104(9):801–823, 1997. ISSN 00029890, 19300972. URL <http://www.jstor.org/stable/2975286>.
- [12] D. R. Cox. *Principles of Statistical Inference*. Cambridge University Press, 2006. doi: 10.1017/CBO9780511813559.

- [13] Homero de Leon-Delgado, Rolando J. Praga-Alejo, David S. Gonzalez-Gonzalez, and Mario Cantú-Sifuentes. Multivariate statistical inference in a radial basis function neural network. *Expert Systems with Applications*, 93:313 – 321, 2018. ISSN 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2017.10.024>. URL <http://www.sciencedirect.com/science/article/pii/S095741741730698X>.
- [14] Real Academia Española, 2018. URL <https://dle.rae.es/srv/fetch?id=GjpdTiC>.
- [15] Excel. Microsoft excel. URL <https://products.office.com/es-mx/excel?rtc=1>.
- [16] Jianqing Fan, Fang Han, and Han Liu. Challenges of Big Data analysis. *National Science Review*, 1(2):293–314, 02 2014. ISSN 2095-5138. doi: 10.1093/nsr/nwt032. URL <https://doi.org/10.1093/nsr/nwt032>.
- [17] Joan Garfield. The challenge of developing statistical reasoning. *Journal of Statistics Education*, 10(3):null, 2002. doi: 10.1080/10691898.2002.11910676. URL <https://doi.org/10.1080/10691898.2002.11910676>.
- [18] Joan Garfield and Iddo Gal. Teaching and assessing statistical reasoning. *Developing mathematical reasoning in grades K-12*, pages 207–219, 1999.
- [19] Zoubin Ghahramani. Unsupervised learning. In *Summer School on Machine Learning*, pages 72–112. Springer, 2003.
- [20] Nizar Grira, Michel Crucianu, and Nozha Boujemaa. Unsupervised and semi-supervised clustering: a brief survey. In *in 'A Review of Machine Learning Techniques for Processing Multimedia Content', Report of the MUSCLE European Network of Excellence (FP6, 2004*.
- [21] Hadoop. Apache hadoop. URL <https://hadoop.apache.org/>.

- [22] Patti W. Hunter. The politics of large numbers. a history of statistical reasoning. *The Mathematical Intelligencer*, 28(1):69–70, Dec 2006. ISSN 0343-6993. doi: 10.1007/BF02987012. URL <https://doi.org/10.1007/BF02987012>.
- [23] Sergio Jurado, Àngela Nebot, Fransisco Mugica, and Narcís Avellana. Hybrid methodologies for electricity load forecasting: Entropy-based feature selection with machine learning and soft computing techniques. *Energy*, 86:276 – 291, 2015. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2015.04.039>. URL <http://www.sciencedirect.com/science/article/pii/S0360544215004934>.
- [24] Kaggle. Your home for data science. URL <https://www.kaggle.com/>.
- [25] Ludmila I. Kuncheva. *Combining Pattern Classifiers: Methods and Algorithms*. John Wiley & Sons, 2004.
- [26] Kenneth J. Kurtz, Dedre Gentner, and Virginia Gunn. Chapter 4 - reasoningI. In Benjamin Martin Bly and David E. Rumelhart, editors, *Cognitive Science*, pages 145 – 200. Academic Press, San Diego, 1999. ISBN 978-0-12-601730-4. doi: <https://doi.org/10.1016/B978-012601730-4/50006-8>. URL <http://www.sciencedirect.com/science/article/pii/B9780126017304500068>.
- [27] Pedro López-García, Denisse Argote-Espino, and Kamila Fačevicová. Statistical processing of compositional data. the case of ceramic samples from the archaeological site of xalasco, tlaxcala, mexico. *Journal of Archaeological Science: Reports*, 19:100 – 114, 2018. ISSN 2352-409X. doi: <https://doi.org/10.1016/j.jasrep.2018.02.023>. URL <http://www.sciencedirect.com/science/article/pii/S2352409X17305722>.
- [28] Matlab. Matlab. URL <https://www.mathworks.com/products/matlab.html>.

- [29] Manuel Mendoza and Luis E. Nieto-Barajas. Quick counts in the mexican presidential elections: A bayesian approach. *Electoral Studies*, 43:124 – 132, 2016. ISSN 0261-3794. doi: <https://doi.org/10.1016/j.electstud.2016.06.007>. URL <http://www.sciencedirect.com/science/article/pii/S0261379415300305>.
- [30] MikeRayMSFT. What is polybase? - sql server. URL <https://docs.microsoft.com/en-us/sql/relational-databases/polybase/polybase-guide?view=sql-server-ver15>.
- [31] Thomas M. Mitchell. *Machine Learning*. McGraw-Hill, Inc., New York, NY, USA, 1 edition, 1997. ISBN 0070428077, 9780070428072.
- [32] Toshinori Munakata. Fundamentals of the new artificial intelligence - neural, evolutionary, fuzzy and more, second edition. In *Texts in Computer Science*, 2007.
- [33] MySQL. The world's most popular open source database. URL <https://www.mysql.com/>.
- [34] H. C. Nguyen, R. Zecchina, and J. Berg. Inverse statistical problems: from the inverse ising problem to data science. *Advances in Physics*, 66(3):197–261, 2017. URL www.scopus.com. Cited By :43.
- [35] Octave. Gnu octave. URL <http://www.gnu.org/software/octave/>.
- [36] Y. Pawitan. *In All Likelihood: Statistical Modelling and Inference Using Likelihood*. Oxford science publications. OUP Oxford, 2001. ISBN 9780198507659. URL <https://books.google.com.mx/books?id=M-3pSCVxV5oC>.
- [37] Theodore M. Porter. *The rise of statistical thinking: 1820-1900*. Princeton Univ. Press, 2011.

- [38] David Powers and Ailab. Evaluation: From precision, recall and f-measure to roc, informedness, markedness & correlation. *J. Mach. Learn. Technol*, 2:2229–3981, 01 2011. doi: 10.9735/2229-3981.
- [39] R programming. The r project for statistical computing. URL <https://www.r-project.org/>.
- [40] Python. Python software foundation. URL <https://www.python.org/>.
- [41] Alan Ramírez-Noriega, Reyes Juárez-Ramírez, and Yobani Martínez-Ramírez. Evaluation module based on bayesian networks to intelligent tutoring systems. *International Journal of Information Management*, 37(1, Part A):1488 – 1498, 2017. ISSN 0268-4012. doi: <https://doi.org/10.1016/j.ijinfomgt.2016.05.007>. URL <http://www.sciencedirect.com/science/article/pii/S0268401216302857>.
- [42] RapidMiner. Lightning fast data science platform for teams: Rapidminer. URL <https://rapidminer.com/>.
- [43] D. Risso, J. Ngai, T. P. Speed, and S. Dudoit. Normalization of rna-seq data using factor analysis of control genes or samples. *Nature biotechnology*, 32(9):896–902, 2014. URL www.scopus.com. Cited By :355.
- [44] Christian Ritz, Florent Baty, Jens C. Streibig, and Daniel Gerhard. Dose-response analysis using r. *PLOS ONE*, 10(12):1–13, 12 2016. doi: 10.1371/journal.pone.0146021. URL <https://doi.org/10.1371/journal.pone.0146021>.
- [45] Luis Alberto Rodríguez-Picón and Víctor Hugo Flores-Ochoa. Estimation of a log-linear model for the reliability assessment of products under two stress variables. *International Journal of System Assurance Engineering and Management*, 8(2):1026–1040, Nov 2017. ISSN 0976-4348. doi: 10.1007/s13198-016-0564-6. URL <https://doi.org/10.1007/s13198-016-0564-6>.

- [46] Frank F. Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65 6:386–408, 1958.
- [47] D. Rumelhart, G. Hinton, and James McClelland. A general framework for parallel distributed processing. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, 1, 01 1986.
- [48] SAS. Analytics, business intelligence and data management. URL https://www.sas.com/es_mx/home.html.
- [49] B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. De Freitas. Taking the human out of the loop: A review of bayesian optimization. *Proceedings of the IEEE*, 104(1):148–175, 2016. URL www.scopus.com. Cited By :411.
- [50] Spark. Apache spark - unified analytics engine for big data. URL <https://spark.apache.org/>.
- [51] Stephen M. Stigler. *The history of statistics: the measurement of uncertainty before 1900*. Belknap Press of Harvard University Press, 1986.
- [52] Tableau. Tableau desktop. URL <https://www.tableau.com/es-mx/products/desktop>.
- [53] Guadalupe Tobias-Lara and Ana Gómez-Blancarte. Assessment of informal and formal inferential reasoning: A critical research review. *Statistics Education Research Journal*, 18:8–25, 05 2019.
- [54] Manuel Villarreal, Carlos Velázquez, José L. Baroja, Alejandro Segura, Arturo Bouzas, and Michael D. Lee. Bayesian methods applied to the generalized matching law. *Journal of the Experimental Analysis of Behavior*, 111(2):252–273, 2019. doi: 10.1002/jeab.506. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/jeab.506>.

- [55] Alex Waigandt and Ze Wang. *An introduction to statistical reasoning in quantitative research*. Morris Publishing, 01 2010.
- [56] Weka. Weka 3: Machine learning software in java. URL <https://www.cs.waikato.ac.nz/ml/weka/>.
- [57] A. M. Winkler, G. R. Ridgway, M. A. Webster, S. M. Smith, and T. E. Nichols. Permutation inference for the general linear model. *NeuroImage*, 92:381–397, 2014. URL www.scopus.com. Cited By :933.

Capítulo 5

Modelos y Razonamiento Causal

L. Enrique Sucar

Instituto Nacional de Astrofísica, Óptica y Electrónica

5.1. Introducción

Recientemente hay un gran auge en el descubrimiento de conocimiento a partir de datos, dada la gran cantidad de datos disponibles y la esperanza de que a partir de los datos podamos encontrar información y conocimiento relevante que nos ayude a tomar mejores decisiones. Sin embargo, lo que obtenemos de los datos con la mayor parte de las técnicas de aprendizaje de máquina (*machine learning*) actuales puede ser engañoso. Por ejemplo, podríamos encontrar en una base de datos de la población mundial, que hay una correlación inversa entre el consumo de vino y la probabilidad de enfermedades cardíacas; es decir, personas que toman más vino tienden a tener menor incidencia de problemas cardíacos. Esto nos podría llevar a concluir que debemos promover el consumo de vino para reducir el riesgo de enfermedades cardíacas. Pero esto puede deberse a otra variable, en este caso el nivel de ingreso: personas con altos ingresos tienden a tomar más vino y a la vez a tener menos problemas cardíacos por una mejora atención

médica. Es decir, hay una tercera variable que explica la correlación entre las dos variables originales (esto se conoce como “cofactores”). El problema es que los algoritmos de aprendizaje de datos, en general, encuentran “asociaciones” entre variables y no necesariamente relaciones de “causa-efecto”. Por lo que si queremos obtener un conocimiento más profundo de los datos que ayude a explicar el fenómeno y tomar mejores decisiones, necesitamos descubrir un “modelo causal”, que represente las relaciones de causa-efecto entre los datos. Esto se conoce como “descubrimiento causal”. La formalización de los modelos causales y el desarrollo de técnicas de descubrimiento causal es muy reciente; y está empezando a tener varias aplicaciones importantes en economía, políticas públicas, genética, neurociencias, etc. En este capítulo haremos una breve reseña histórica del desarrollo de los modelos causales, y luego analizaremos en más detalle uno de los modelos que han surgido recientemente, los modelos gráficos causales. Revisamos el trabajo que se está iniciando en México en este campo, y concluimos con algunos retos y perspectivas futuras.

5.2. Desarrollo de los modelos casuales

Los humanos tendemos a pensar en términos causales, ciertas cosas o eventos causan otros eventos. Por ejemplo, manejar bajo la influencia del alcohol puede causar accidentes, fumar causa cáncer, la lluvia causa que la calle este mojada, etc., etc. Frecuentemente nos preguntamos, ¿Porqué? ¿Porqué me enfermé?, ¿Porqué reprobé el examen?, ¿Porqué perdió mi equipo? Buscamos entender el mundo en términos de causas y efectos. La ciencia de la causalidad trata de formalizar este proceso – entender el razonamiento causal y emularlo en las computadoras. En los últimos 20-30 años han ocurrido avance importantes en la formalización de la causalidad. Se han desarrollado diversos modelos para representar las relaciones causales y para realizar “razonamiento causal”. Diversos investigadores consideran que la representación y el razonamiento causal son esenciales para construir máquinas “realmente” inteligentes [4]. Judea Pearl afirma: “el razona-

miento causal les permitirá a las máquinas reflexionar sobre sus errores, encontrar las debilidades en su software, funcionar como entidades morales y conversar naturalmente con las personas sobre sus decisiones e intenciones”. A pesar de que la causalidad es algo natural para las personas, y que es importante para diversas áreas de la ciencia y la sociedad en general, su desarrollo ha sido muy lento y accidentado. La historia inicia con Galton, un científico inglés que buscaba explicación a ciertos fenómenos. Por ejemplo, porqué los hijos de personas muy altas tienden a ser menos altos que sus padres. Buscaba una explicación causal para esto, pero al no encontrarla se conformó con definir la “correlación”; es decir, que ciertas cantidades están relacionadas con otras cantidades. Por ejemplo, hay una correlación entre la altura de una persona y la de sus padres e hijos. Si graficamos la altura del hijo (eje Y) contra la altura del padre (eje X), y consideramos muchos ejemplos (puntos de la gráfica), podemos aproximar la relación entre dichos puntos como una línea recta, y observamos que valores muy altos de X tienden a coincidir con valores más bajos de Y, y viceversa. Esto se conoce como “regresión a la media”, un fenómeno común en la naturaleza (de no ser así la altura de los descendientes seguiría aumentando de generación en generación y habría individuos de 3 o más metros de altura). De esta forma nació el campo de la estadística. Pearson fue un discípulo de Galton, y probablemente el experto en estadística más famoso en la historia. Pearson terminó la tarea de separar a la causalidad de la estadística. Él consideraba que la causalidad era simplemente un caso especial de la correlación, esto es la correlación en el límite. Como veremos más adelante esto es falso, son dos conceptos diferentes aunque relacionados. ¡Causalidad implica correlación pero NO viceversa! Entonces el desarrollo de la ciencia de la causalidad permaneció dormido por muchos años. Como es común en estos casos, una persona fuera de la comunidad dominante fue quien inició el desarrollo de los modelos causales, *Sewal Wright*. Wright estudiaba genética y analizaba el color de la piel de los conejillos de indias. Encontró que los cambios de color no se podían explicar en base sólo a factores genéticos, su hipótesis era que el color de piel debería ser una combinación de genética y factores ambientales. Desarrolló un modelo que explica los factores

que determinan el color de piel de los conejillos de indias; a esto le llamó un “diagrama de trayectorias” (*path diagram*). Podemos considerarlo como el primer modelo causal, era el año de 1920. La Figura 5.1 muestra el diagrama de trayectorias original de Wright. El modelo representa las relaciones causales entre los diferentes aspectos (variables) que intervienen en determinar el color de piel de los conejillos de indias; cada una de estas relaciones tiene un “peso” que indica que tanta importancia tiene dicho factor (Wright suponía un modelo lineal pesado). Mediante este modelo, conociendo los colores de piel de los padres y los factores ambientales, se pueden estimar los colores de piel de los descendientes. El modelo fue validado con datos reales con buenos resultados. Este modelo es un antecedente directo de los modelos gráficos causales que veremos más adelante.

A pesar de la claridad y buenos resultados del modelo de Wright, la comunidad estadística no lo aceptó y ¡permaneció básicamente ignorado por 40 años! Finalmente, en los años 60’s del siglo pasado empezaron a surgir algunos modelos que intentaban representar causalidad, entre ellos los modelos de ecuaciones estructurales en sociología y los modelos de ecuaciones simultáneas en economía. En los años 90’s surgen los modelos gráficos causales.

5.3. Modelos gráficos causales

Los modelos gráficos causales han tomado fuerza en los últimos años dado que son transparentes (fáciles de entender); y además se han desarrollado técnicas para hacer predicciones a partir de estos modelos. Nos enfocaremos en las redes bayesianas causales [3, 6] Las redes bayesianas causales (CBN, por sus siglas en inglés) son grafos acíclicos dirigidos donde los nodos representan variables y los arcos relaciones causales. A diferencia de las redes bayesianas, todos los arcos representan relaciones causa-efecto, por lo que implican suposiciones más fuertes que las redes bayesianas. La Figura 5.2 muestra un ejemplo sencillo de una CBN. La semántica de las CBNs se puede definir en base a

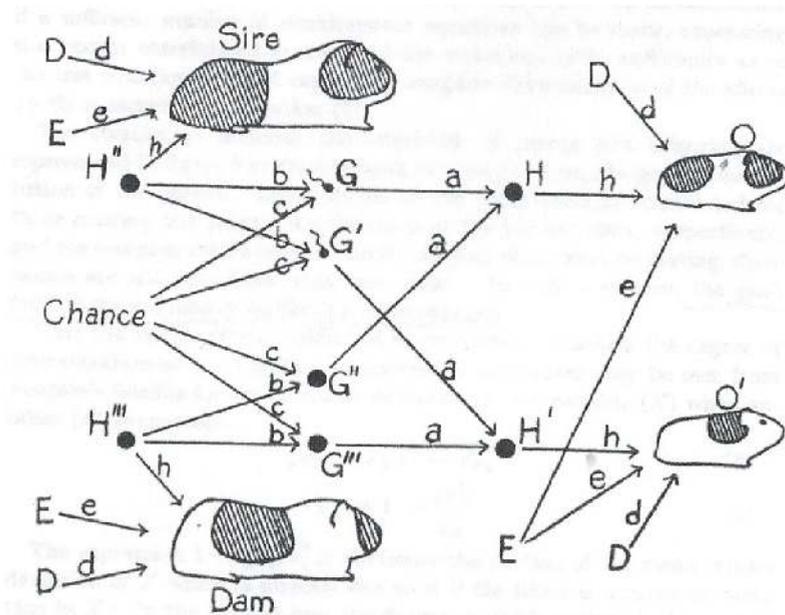


Figura 5.1: Diagrama causal que modela los factores que determinan el color de piel de los conejillos de india. D, factores de desarrollo; E, factores ambientales; G, factores genéticos; H, factores combinados de los padres. Las letras minúsculas en los enlaces representan el “peso” de las relaciones. Figura tomada de [4]

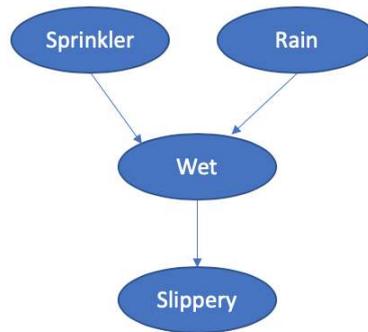


Figura 5.2: Ejemplo de una CBN. La lluvia (*Rain*) o el aspersor (*Sprinkler*) causan piso mojado (*Wet*), que a su vez lo hace resbaloso (*Slippery*).

“intervenciones”; es decir, el fijar el valor de una o más variables y establecer su efecto en las demás variables. Esto se conoce como “razonamiento causal”.

En forma análoga a las redes bayesianas, las CBNs tienen asociadas probabilidades condicionales que establecen la “fuerza” de las relaciones causales. Dichas probabilidades se establecen para cada variable dados sus padres en el grafo. Por ejemplo, en el modelo de la figura 5.2, habría una tabla de probabilidad que indica que tan probable es que el piso este resbaloso dado que está mojado. El razonamiento causal consiste en contestar preguntas causales a partir de un modelo. Hay dos tipos básicos de razonamiento causal: (i) predicciones, y (ii) contra factuales. La predicción nos permite contestar la pregunta: ¿Cuál es el efecto en Y de intervenir (asignar un valor) X ? Por ejemplo, si tenemos un modelo causal sobre las embolias cerebrales, ver figura 5.3, ¿cuál sería el efecto de una dieta no saludable sobre (la probabilidad de sufrir una) embolia?

El procedimiento para realizar predicciones dado una CBN es el siguiente:

1. Eliminar todos los arcos que apuntan a la variable (o variables) que se van a intervenir.
2. Fijar el valor de la(s) variable(s) a intervenir.

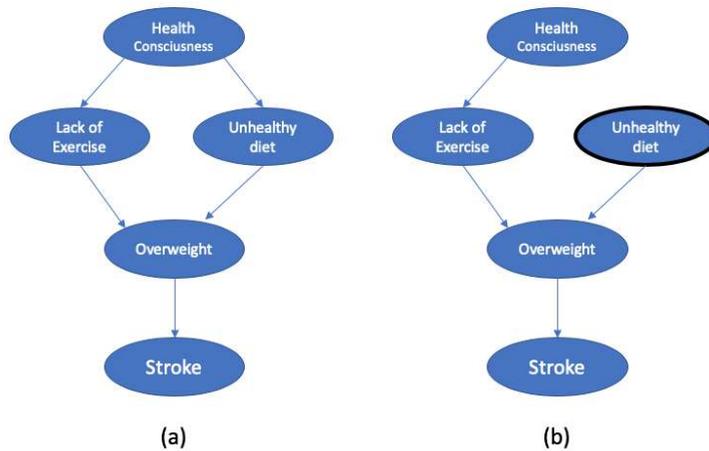


Figura 5.3: (a): CBN que representa un modelo causal hipotético y simplificado de sufrir una embolia: la falta de ejercicio (*Lack of Exercise*) y una dieta no saludable (*Unhealthy diet*) pueden causar sobrepeso (*Overweight*), lo que puede ocasionar una embolia (*Stroke*). El ejercicio y la dieta están determinados por la conciencia de la salud (*Health Consciouness*). (b): modelo modificado para la predicción de la probabilidad de embolia (*Stroke*) dada una dieta no saludable (*Unhealthy diet*).

3. Calcular las probabilidades de las demás variables en el modelo modificado mediante propagación de probabilidades (es el mismo procedimiento que se utiliza para inferencia en las redes bayesianas).

Un ejemplo se ilustra en la figura 5.3. A la izquierda observamos el modelo causal original, y a la derecha el modelo modificado al intervenir la variable dieta. Los contra factuales tiene que ver con la imaginación, algo común en los humanos pero todavía no en las máquinas. Es decir, contestar preguntas del tipo ¿qué hubiera pasado si? En el ejemplo de la embolia: María sufrió una embolia cerebral, ¿la hubiera sufrido si hubiera realizado más ejercicio? El procedimiento para evaluar los contra factuales es:

1. Modificar el modelo en base a la nueva evidencia; es decir, olvidar los valores de las variables que queremos evaluar.
2. Intervenir la(s) variable(s) correspondiente(s) de acuerdo a la evidencia hipotética, y eliminar los arcos que apuntan a dicha variable(s).
3. Realizar la propagación de probabilidades en el modelo modificado, de forma de estimar la probabilidad de la variable de interés.

Continuando con el ejemplo de la embolia, en la figura 5.4 se muestra el caso del contra factual en el cual deseamos saber si la persona que sufrió una embolia la hubiera sufrido si hubiera hecho más ejercicio. Del lado izquierdo se ilustra el modelo original y del derecho el modificado en el cual: (a) se ha quitado el valor a embolia (se asume desconocido), (b) se ha eliminado el arco que apunta a la variable ejercicio, (c) se asigna el valor verdadero (si hace ejercicio) a la variable ejercicio. Si se hace la propagación de probabilidades sobre este modelo modificado, contestamos la pregunta.

El contar con un modelo causal de un fenómeno tiene grandes ventajas, ya que nos permite contestar este tipo de preguntas sin la necesidad de hacer experimentos en el mundo real. La manera tradicional de contestar las preguntas causales es mediante experimentos controlados en el que se fijan ciertas variables y se ve el efecto en otras.

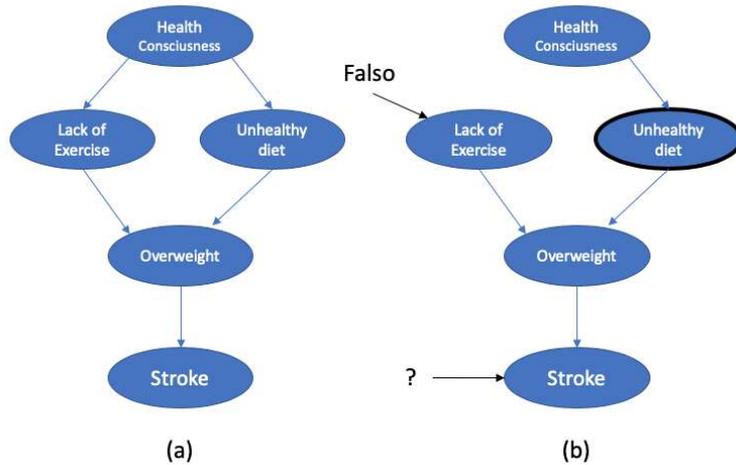


Figura 5.4: (a): CBN original. (b): modelo modificado para el contra factual: ¿Hubiera sufrido una embolia (*Stroke*) su hubiera realizado más ejercicio (*Lack of Exercise*)?

Por ejemplo, en medicina si queremos saber si cierto nuevo medicamento sirve para curar cierta enfermedad, se aplica dicho medicamento a un número de personas, y se compara el efecto con otro grupo de personas que usan el medicamento tradicional. Para esto se tiene que asegurar que los dos grupos sean “similares”, de forma que no haya otras variables (co-factores) que afectan los resultados. Estos experimentos suelen ser muy costosos, y en ocasiones no son éticos e incluso no son posibles. En cambio, si contáramos con un CBN del dominio, nos evitamos hacer dichos experimentos en el mundo, simplemente los “simulamos” en el modelo mediante razonamiento causal. El reto se vuelve entonces contar con el modelo causal, por lo que un área de investigación muy interesante es como puedo obtener dichos modelos causales a partir de datos, lo que se conoce como “descubrimiento causal”.

5.4. Descubrimiento causal

Aprender modelos causales a partir de datos sin realizar intervenciones implica varios retos. Si encontramos que dos variables, X y Y , son dependientes, sin conocimiento adicional no es posible saber si “ X causa Y ” o “ Y causa X ”. Incluso puede ser que exista una tercera variable, Z , que es una causa común de X y Y , provocando su dependencia. Las relaciones de dependencia son diferentes a las relaciones de causalidad. Por ejemplo, los dos modelos de la figura 5.5 corresponden a las mismas relaciones de independencia: “ X y Z son independientes dado Y ”; pero son muy diferentes en términos de causalidad: el modelo de la izquierda representa que X causa Y , y Y causa Z , mientras que el de la derecha que Y es una causa común de X y Z .

Una forma de aprender modelos causales es usando algoritmos desarrollados para aprender redes bayesianas, los cuales se basan en evaluar las relaciones de dependencia e independencia entre las variables. Por ejemplo, el algoritmo PC [5] infiere a partir de los datos un grafo acíclico dirigido basado en estimar las relaciones de independencia mediante pruebas estadísticas entre las variables del fenómeno de interés. Sin embargo,

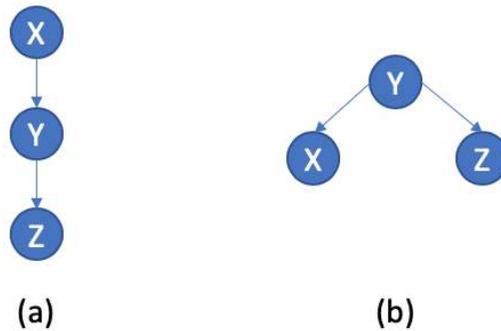


Figura 5.5: Dos modelos gráficos que representan las mismas relaciones de independencia (X independiente de Z dado Y), pero diferentes relaciones causales.

como vimos en el ejemplo anterior, puede haber varios modelos que son equivalentes, es decir que representan las mismas relaciones de dependencia e independencia. Entonces lo que en general obtenemos a partir de algoritmos basados en pruebas estadísticas es una “clase de equivalencia” – varios modelos que son equivalentes desde el punto de vista estadístico pero diferentes en cuanto a las relaciones causales. La figura 5.6 ilustra un ejemplo de una clase de equivalencia, donde los arcos no determinados son flechas dobles. En este caso, la clase representa cuatro posibles modelos causales diferentes. Para tratar de llegar a un modelo único a partir de una clase de equivalencia existen varias alternativas:

1. Incorporar conocimiento previo al algoritmo de aprendizaje.
2. Realizar pruebas adicionales entre las variables cuyo arco no esté definido.
3. Hacer intervenciones en el fenómeno de forma de obtener más información. Actualmente se realiza investigación en estas diferentes alternativas para el descubri-

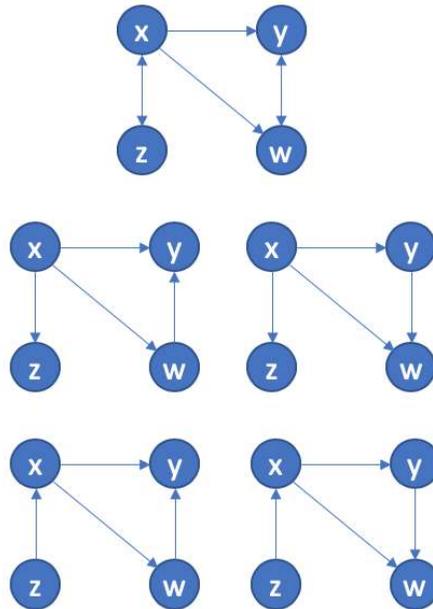


Figura 5.6: En la parte superior se muestra la clase de equivalencia (obtenida con algún algoritmo de aprendizaje de redes bayesianas), las flechas dobles representan enlaces indeterminados. Abajo se muestran los 4 posibles modelos causales.

miento de modelos causales. En la siguiente sección veremos algunos ejemplos de investigaciones realizadas en México.

5.5. Principales desarrollos en México

En México se está empezando a incursionar en esta área en el modelado de las relaciones de conectividad efectiva en el cerebro mediante redes bayesianas causales, así como en modelos predictivos para la detección temprana de fragilidad en los adultos mayores.

En el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) se ha estado investigando como obtener las relaciones de conectividad efectiva en el cerebro a partir de datos de espectrografía funcional infrarroja cercana (fNIRS por sus siglas en inglés). La conectividad efectiva se refiere a cuando la activación de cierta zona del cerebro ocasiona que otra zona de active, lo que se puede ver como una relación causal. El conocer este mapa de conectividad efectiva puede ayudar a entender mejor el funcionamiento del cerebro. Se han propuesto dos estrategias alternativas para aprender estos modelos causales a partir sólo de datos observacionales, ya que es complejo hacer intervenciones. Por un lado se ha propuesto el uso de conocimiento previo, en particular del conectoma del cerebro. El conectoma establece dónde hay conexiones físicas entre diferentes regiones del cerebro; esto limita donde puede haber relaciones causales, ya que si no hay una conexión física no puede haber una relación causal. Al utilizar esta información se reduce el número de enlaces indeterminados en el modelo [2]. Por otro lado, dado que aún pueden quedar enlaces indeterminados, se desarrolló un algoritmo para tratar de determinar la dirección del arco. Dado el enlace indefinido “ $X—Y$ ”, se estima el efecto causal promedio de X hacia Y y de Y hacia X ; el que de mayor define la dirección del enlace. Pruebas preliminares con datos sintéticos muestran buenos resultados [1].

5.6. Retos y Perspectivas Futuros

El desarrollo de los modelos causales está apenas en su infancia, y hay aún muchos retos que resolver; así como un gran potencial para diversas aplicaciones. Se han realizado importantes avances principalmente en la representación y razonamiento causal, pero en el descubrimiento causal aún hay mucho por hacer. El reto principal es el aprendizaje de modelos causales bajo suposiciones menos restrictivas que las actuales, y a partir de pocos datos observacionales o en combinación con algunas intervenciones. El contar con modelos causales puede ayudar a tomar mejores decisiones a un menor costo en varios dominios, en particular en políticas públicas, en economía, en medicina, entre otras.

Por ello es importante el desarrollo de estos modelos, lo que implica la integración de equipos multidisciplinarios, con expertos en modelado causal y en las diferentes aplicaciones. Finalmente, como mencionamos anteriormente, los modelos causales serán un elemento esencial en el desarrollo de sistemas realmente inteligentes, que puedan explicar sus decisiones y estar conscientes de sus limitaciones. Para esto será necesario la integración de estos modelos con otros algoritmos de IA, por ejemplo con las técnicas de aprendizaje profundo enfocadas básicamente a aspectos de percepción. Incorporando la capacidad de razonamiento causal, permitirá a los sistemas actuales ir más allá de simplemente aprender asociaciones, pudiendo razonar sobre la situación y tomar mejores decisiones. Un reto para México es la formación de recursos humanos en estos temas, así como el desarrollo de más grupos de investigación.

Bibliografía

- [1] Samuel Montero-Hernandez, Felipe Orihuela-Espina, and Luis Enrique Sucar. Intervals of causal effects for learning causal graphical models. In Václav Kratochvíl and Milan Studený, editors, *Proceedings of the Ninth International Conference on Probabilistic Graphical Models*, volume 72 of *Proceedings of Machine Learning Research*, pages 296–307, Prague, Czech Republic, 11–14 Sep 2018. PMLR. URL <http://proceedings.mlr.press/v72/montero-hernandez18a.html>.
- [2] Samuel Antonio Montero-Hernández, Felipe Orihuela-Espina, Javier Herrera-Vega, and Luis Enrique Sucar. Causal probabilistic graphical models for decoding effective connectivity in functional near infrared spectroscopy. In *Proceedings of the Twenty-Ninth International Florida Artificial Intelligence Research Society Conference, FLAIRS 2016, Key Largo, Florida, USA, May 16-18, 2016*, pages 686–689, 2016. URL <http://www.aaai.org/ocs/index.php/FLAIRS/FLAIRS16/paper/view/12913>.

- [3] Judea Pearl. *Causality: models, reasoning, and inference*. Cambridge University Press, 2000. ISBN 052189560X. URL <https://dl.acm.org/citation.cfm?id=1642718>.
- [4] Judea Pearl and Dana Mackenzie. *The book of why: the new science of cause and effect*. ISBN 046509760X.
- [5] Peter Spirtes and Clark Glymour. An Algorithm for Fast Recovery of Sparse Causal Graphs. *Social Science Computer Review*, 9(1):62–72, apr 1991. ISSN 0894-4393. doi: 10.1177/089443939100900106. URL <http://journals.sagepub.com/doi/10.1177/089443939100900106>.
- [6] Luis Enrique Sucar. *Probabilistic graphical models: principles and applications*. ISBN 9781447166986. URL https://www.researchgate.net/publication/278963064_Probabilistic_Graphical_Models_Principles_and_Applications

Capítulo 6

Razonamiento Semántico

Rocío Aldeco-Pérez

Universidad Nacional Autónoma de México

María Josefa Somodevilla García

María de la Concepción Pérez de Celis Herrero

Benemérita Universidad Autónoma de Puebla

María Auxilio Medina Nieto

Universidad Politécnica de Puebla

José Alfredo Sánchez Huitrón

Laboratorio Nacional de Informática Avanzada

Yolanda Margarita Fernández Ordóñez

Colegio de Postgraduados

Reyna Carolina Medina Ramírez

Universidad Autónoma Metropolitana

6.1. Introducción

Desde los inicios de la Inteligencia Artificial hace más de 60 años, el objetivo de los científicos de datos ha sido crear sistemas capaces de realizar tareas que tradicionalmente requerían inteligencia humana.

Para lograrlo, estos sistemas necesitarían conocimientos sobre las funciones que se pretendía que desempeñaran. Desde el principio, hubo dos enfoques principales para hacer que estos sistemas fueran bien informados: enseñarles explícitamente lo que necesitan saber, o hacer que aprendan de la experiencia.

Como se ha explicado en los capítulos anteriores, este último enfoque (aprender de la experiencia) el del aprendizaje máquina (o *machine learning* en inglés), ha sido mucho más prominente en los últimos años y, para algunos, se ha convertido en sinónimo de IA. Esta técnica ha demostrado un gran valor en toda una gama de tareas de clasificación y predicción, como la categorización de las solicitudes de ayuda, la identificación de transacciones potencialmente fraudulentas, la formulación de recomendaciones de productos, la determinación de las intenciones de los usuarios en los *chatbots* y muchas más. Sin embargo, ese no es el panorama completo; la IA puede, y debe, hacer mucho más.

Hay muchas tareas que requieren un razonamiento explícito utilizando el conocimiento que se tiene del dominio del problema y, a menudo, sobre el mundo en general (es decir, el “sentido común”). Tareas como formar un equipo de proyecto, planear una cena, coordinar una respuesta a un desastre natural, o incluso tareas más cotidianas, como preparar el almuerzo, comprar un auto, o entender un artículo de periódico son ejemplos que requieren de nuestro conocimiento del mundo a nuestro alrededor.

En cada caso, la tarea es más compleja que sólo seleccionar entre un conjunto de opciones posibles o determinar el valor de una variable en particular, y lo que es más importante, se basa en información o conocimientos que no formaban parte de los “datos de entrada”. Además, estas tareas requieren ser capaces de combinar dinámicamente el conocimiento para responder preguntas o llegar a conclusiones.

Este tipo de razonamiento requiere que el conocimiento sea modelado de manera que una máquina pueda procesarlo eficientemente, es decir, usando una ontología o una base de conocimiento.

6.2. Modelado semántico: razonamiento e inferencia

En contraste con el aprendizaje automático, que resulta en una red de vínculos ponderados entre entradas y salidas (a través de capas intermedias de nodos), el enfoque del modelado semántico se basa en crear representaciones explícitas y comprensibles para el ser humano de los conceptos, relaciones y reglas que componen el dominio de conocimiento deseado.

Hay varios niveles de fidelidad con los cuales este conocimiento puede ser representado y los niveles correspondientes de experiencia y gastos asociados con el modelado de este conocimiento. Para algunas representaciones más simples, un “grafo de conocimiento” compuesto de la 3-tupla de la forma $\langle \text{objeto}, \text{predicado}, \text{objeto} \rangle$, puede ser posible automatizar (parcialmente) la adquisición y la creación de dicho conocimiento. Las representaciones más ricas, como la lógica formal (ver Capítulo 2), son a la vez más complejas y más poderosas, y normalmente requieren la intervención humana en el proceso de adquisición y autoría.

Afortunadamente, no es necesario construir estos modelos desde cero; a menudo se amplían los modelos de conocimiento existentes, incluyendo las ontologías específicas de dominio y bases de conocimiento más amplias. Estos conceptos se detallaran en las siguientes secciones.

El valor que se deriva del modelado de conocimiento explícito y declarativo es que no sólo se puede recuperar dicho conocimiento, sino que se puede razonar mecánicamente con él. Además, el proceso de razonamiento automático, o inferencia, se puede combinar dinámicamente con el conocimiento para responder preguntas (inferencia

hacia atrás) o para sacar conclusiones (inferencia hacia adelante) en formas que no fueron necesariamente anticipadas y surgen durante los procesos. Es decir, las soluciones semánticas se basan en el modelado de aspectos del mundo y utilizan razonamientos similares a los humanos sobre esos modelos de conocimiento, en lugar de basarse en algoritmos procedimentales que especifican cómo se debe realizar una tarea (es decir, la programación tradicional) o las correlaciones aprendidas entre entradas y salidas (es decir, el aprendizaje automático).

Además de poder abordar un conjunto diferente de problemas a los que aborda el aprendizaje de máquina, los sistemas basados en el conocimiento ofrecen mucha más transparencia en las conclusiones a las que llegan que sus opuestos que son más opacos. Esto hace que el modelo sea más fácil de mantener, especialmente cuando algunos aspectos del contexto cambian lo que podría hacer los resultados anteriores sean inválidos.

Estas soluciones son relativamente simples y muy útiles, dada la disponibilidad de una potencia de cálculo barata y escalable, la gran cantidad de datos disponibles como materia prima y la ubicuidad de las interacciones entre el hombre y la computadora. Descubrir correlaciones a partir de cantidades masivas de datos es algo que las máquinas hacen bien. Recurrir a un enorme y diverso repositorio de conocimientos, saber qué aplicar en cada momento y ser capaz de combinar estos conocimientos para resolver problemas complejos es una tarea muy diferente y, posiblemente, mucho más difícil.

Como consecuencia de esta explosión de datos y el uso de dispositivos pervasivos, ha permitido el surgimiento de tecnologías asociadas con esta representación del conocimiento. Ejemplos de estas son las llamadas “Ontologías”, que son parte de la propuesta del “Web Semántico” [12], el cual tiene por objetivo que las páginas Web se auto-describan usando un código estándar *Resource Description Framework* (RDF) de forma tal que puedan ser interpretadas por la computadora, a diferencia de las páginas Web usuales, que están destinadas al consumo humano. Las tecnologías asociadas a la representación del conocimiento en ontologías han tenido mucho desarrollo, y han dado lu-

gar a estándares de lenguajes tales como XML, RDF, OWL y otros, así como múltiples herramientas para manejarlos, tanto para su almacenamiento como para su explotación usando formas limitadas de razonamiento automático. En las siguientes secciones abordamos estos temas con más detalles.

6.3. Web Semántica

La web semántica también llamada también *Web 3.0* o *Linked Data*, es una funcionalidad de la Web que permite encontrar, compartir y combinar la información más fácilmente. Es una iniciativa de Tim Berners-Lee [13] para permitir que la información que reside en la red sea accesible y comprensible no sólo por los humanos, sino también por las máquinas. Esta Web extendida propone nuevas técnicas y paradigmas para la representación del conocimiento que faciliten la localización, compartición e integración de recursos a través de la Web. Estas nuevas técnicas se basan en la introducción de conocimiento semántico explícito que describa y/o estructure la información y servicios disponibles, de forma apropiada de ser procesada automáticamente por un software.

6.3.1. Estructura de la Web Semántica

La web semántica se compone de una serie de recursos, los cuales se vinculan a través de relaciones taxonómicas y semánticas como se muestra en la figura 6.1. Esta composición de la web semántica se basa en la descripción del significado y en la manipulación automática de estas descripciones.

Frente al crecimiento caótico de recursos, la web semántica aboga por clasificar, dotar de estructura y anotar los recursos con semántica explícita procesable por máquinas. La figura 6.1 ilustra esta propuesta donde la web se asemeja a un grafo formado por nodos del mismo tipo, y arcos igualmente indiferenciados. Por ejemplo, no se hace distinción entre la página personal de un autor y el portal de una biblioteca, como tampoco se distinguen explícitamente los enlaces a los documentos que escribe un autor

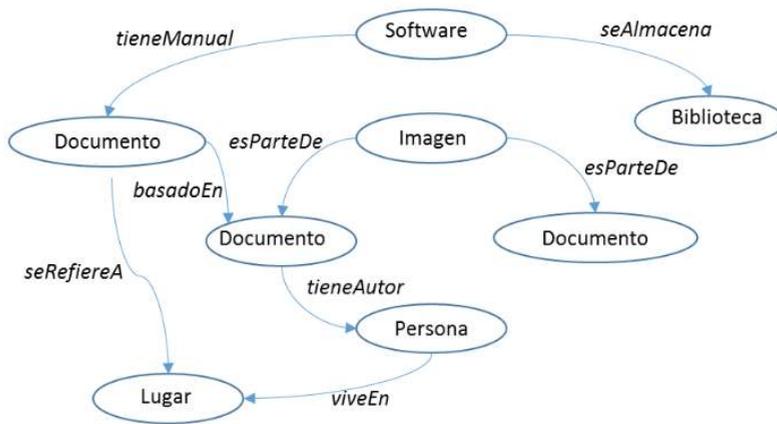


Figura 6.1: Vista de la Web Semántica.

del enlace al lugar donde vive este. Por el contrario en la web semántica cada nodo (recurso) tiene un tipo (autor, documento, software, biblioteca), y los arcos representan relaciones explícitamente diferenciadas (tieneAutor, esParteDe, seAlmacena).

6.3.2. Modelo Constructivo de La Web Semántica

El proyecto de la web semántica está formado por arquitectura de capas, dada la diversidad de normas, protocolos, lenguajes y especificaciones involucradas. En la figura 6.2 se presenta un diagrama realizado por Tim Berners-Lee, de gran capacidad expresiva, el cual puede servir como aproximación visual al conjunto de tecnologías componen la misma.

En la Tabla 6.1 se presenta de forma más detallada el propósito de cada una de las capas de la Figura 6.1. Note que la estructura de capas sugiere un proceso de transformación de los documentos que va desde su representación hasta la generación de conocimiento.

Capa	Descripción
1 Unicode + URI	Estándares para la localización de recursos de información en la web de forma inequívoca y única como son los URIs (Uniform Resource Identifiers) y la norma internacional Unicode para la codificación de caracteres a nivel internacional.
2 XML+NS+XML Schema	XML (eXtensible Markup Language), como base sintáctica para la estructuración del contenido en la web, así como el empleo de espacios de nombres (NS) para asociar con precisión cada propiedad con el esquema que define dicha propiedad y esquemas (XML Schema) para definir qué elementos debe contener un documento XML, cómo están organizados, qué atributos y de qué tipo pueden tener sus elementos.
3 RDF + RDFschema	Un modelo básico para establecer propiedades sobre los recursos, para el que se empleará RDF (Resource Description Framework), así como un modelo para definir relaciones entre los recursos por medio de clases y objetos, que se expresan mediante esquemas en RDF RDF Schema).
4 Vocabularios de Ontologías	Lenguajes para la representación de ontologías que permitan la interoperabilidad y reutilización entre ontologías de diversos dominios del conocimiento en el web, cuya base se encuentra en RDF Schema.
5 Lógica	Una capa lógica que permita realizar consultas e inferir conocimiento, donde estarían las ontologías, agentes software y servicios web como estructuras para lograr interoperabilidad entre aplicaciones y sistemas de información heterogéneos.
6 Pruebas	Se considera que una computadora alcanza la máxima fiabilidad en sus razonamientos cuando es capaz de realizar demostraciones o, cuando es capaz de justificar el motivo por el cual tomó una decisión.
7 Confianza	Una capa de seguridad que permita asignar niveles de fiabilidad a determinados recursos, de forma comprobable posteriormente por los agentes, para lo que se utilizarán firmas digitales y redes de confianza.

Tabla 6.1: Los 7 niveles de la Web Semántica Capa Descripción.



Figura 6.2: La Web semántica vista como un sistema de capas (fuente: [12]).

Considerando la estructura de capas de la figura 6.2, la web semántica tiene la capacidad de construir una base de conocimientos sobre las preferencias de los usuarios en combinación con la información disponible en Internet, lo que la hace capaz de atender de forma exacta las demandas de información de los usuarios.

6.3.3. Aplicación de la Web Semántica

La principal ventaja de la web semántica es recuperar información. Ésta permite al usuario dejar en manos del software, tareas de procesamiento o razonamiento de un determinado contenido [12]. Por otra parte, el introducir significado a una web mejora la eficacia de los buscadores, ya que facilita su tarea de estudio del documento.

La Web Semántica facilita la localización de recursos, la comunicación entre programas y personas, y el procesamiento y manipulación de datos e información de manera automática a través de la creación de servicios web semánticos [12]. Entre estos servicios web semánticos se incluyen los convertidores a RDF, marcado de documentos con eti-

quetas tipo < *meta* > para facilitar el trabajo de buscadores, vocabularios de metadatos comunes, agentes de software y servicios de confianza. Algunos de estos presentados en las siguientes secciones.

Los servicios mencionados anteriormente pueden ser incorporados en los motores de búsqueda públicos tales como Google o también podrían ser utilizados para hacer el mejor uso del conocimiento en una empresa u organización. Aplicaciones de negocio [34, 38] que incorporan estos servicios están dirigidas a integrar información heterogénea proveniente de diferentes fuentes, eliminar ambigüedad en terminología dentro de un contexto, mejorar la precisión en la información recuperada, identificar información relevante a un dominio y proveer soporte para la toma de decisiones entre los más significativos.

6.3.4. Repositorios Digitales

La web semántica y en especial, iniciativas como la de datos enlazados (o *Linked Data*) han propiciado la publicación, interconexión y compartición de datos abiertos en la web, fomentando la interoperabilidad entre los distintos dominios. Los datos abiertos son datos que pueden ser utilizados, reutilizados y redistribuidos libremente por cualquier persona, y que se encuentran sujetos, cuando más, al requerimiento de atribución y de compartirse de la misma manera en que aparecen. La definición de abierto se entiende dentro del contexto que aprueba el *Open Definition Advisory Council*, en la que el término conocimiento incluye contenidos, como música, películas o libros pero también datos tanto científicos, históricos, geográficos o de cualquier otro tipo e información gubernamental y de otras administraciones públicas¹.

Para que una obra o unos datos sean considerados abiertos deben de ser de acceso fácil (disponible integralmente, a un costo razonable y de forma que pueda ser modificable) y también deben permitir la redistribución, reutilización y participación universal

¹<http://opendefinition.org/>

(ausencia de restricciones tecnológicas, reconocimiento, integridad, sin discriminación de personas o grupos, sin discriminación de ámbitos de trabajo, distribución de la licencia, la licencia no debe ser específica de un paquete y la licencia no debe restringir la distribución de otras obras).

Los datos abiertos pueden clasificarse como datos científicos y datos gubernamentales es decir cuando los datos provienen de centros de investigación (a pesar de tener financiamiento público) estos son considerados datos científicos en tanto que provienen de administraciones públicas como son, entre otro, los datos de transporte, datos geográficos, datos de carácter económico y cultural son considerados como gubernamentales [37]. Todo este conjunto de datos tanto de origen científico como gubernamental pueden ser almacenados en los que se denomina repositorios digitales [27].

Un repositorio digital, se compone de archivos donde se almacenan recursos digitales de manera que estos pueden ser accesibles a través de internet, es decir, es una colección de recursos en línea. Es importante mencionar que, el significado del término 'repositorio digital' ha sido ampliamente debatido; actualmente este significado, se ha ampliado a un compromiso más amplio y general con la administración de materiales digitales; Esto requiere no solo software y hardware, sino también políticas, procesos, servicios y personas, así como contenido y metadatos. Los repositorios deben ser sostenibles, confiables, bien respaldados y bien administrados para funcionar correctamente.

Existen tres tipos principales de repositorios [30]:

- Repositorios institucionales: son los creados por las propias organizaciones para depositar, usar y preservar la producción científica y académica que generan. Supone un compromiso de la institución con el acceso abierto al considerar el conocimiento generado por la institución como un bien que debe estar disponible para toda la sociedad.

- Repositorios temáticos: son los creados por un grupo de investigadores, una institución, etc. que reúnen documentos relacionados con un área temática específica.
- Repositorios de datos: repositorios que almacenan, conservan y comparten los datos de las investigaciones.

6.3.5. Utilización de Ontologías en los repositorios digitales

Para Weinstein y Birmingham [41], las ontologías son una herramienta poderosa para describir escenarios complejos de uso, como puede serlo, una biblioteca digital, donde se pueden identificar y representar formalmente varios conceptos y relaciones entre estos conceptos. El uso de ontologías promueve la integración de nuevos servicios en los ya existentes, y la interoperabilidad con otros sistemas a través de los servicios web semánticos apropiados. Entre las aportaciones del uso de ontologías en repositorios digitales, reportadas en la literatura, podemos mencionar a Deng y Tang [20], quienes hacen uso de las ontologías y la tecnología de agentes para proponer un nuevo modelo de descubrimiento del conocimiento, utilizando ontologías para dos funciones principales: favorecer una mejor clasificación y mejorar la renovación y tasa de precisión de recuperación por medio de búsquedas semánticas. Existen también algunos proyectos relacionados con el diseño y construcción de repositorios digitales basados en ontologías, que ameritan ser mencionados, como es el proyecto JeromeDL. El proyecto JeromeDL [35] es un motor de biblioteca digital semántica. Utiliza Web semántica y tecnologías de redes sociales para mejorar la navegación y la búsqueda de recursos. Con los servicios sociales y semánticos de JeromeDL, cada usuario de la biblioteca puede: marcar libros, artículos u otros materiales interesantes en directorios semánticamente anotados. Los usuarios pueden permitir que otros vean sus marcadores y anotaciones y compartir sus conocimientos dentro de una red social. Esta biblioteca digital de código abierto utiliza

una ontología para definir la estructura de los recursos en RDF; y define los conceptos relacionados solo con la estructura del recurso; la ontología proporciona una capa universal para los metadatos y para la recuperación de contenido; y permite ampliar la descripción de la estructura con nuevos conceptos, sin violar la integridad de los datos existentes y permite la realización de búsquedas semánticas basadas en ontologías.

6.3.6. Conceptos básicos de ontologías y repositorios

Las personas asocian significados a las palabras, interpretan acontecimientos y emiten juicios o conclusiones a partir de hechos, principios o proposiciones. El modelado de capacidades y comportamientos similares en las computadoras se ha investigado ampliamente desde diferentes áreas de conocimiento. Esta sección presenta los componentes y usos de modelos de representación de conocimiento denominados ontologías, las cuales se emplean en el desarrollo de software para la web semántica.

Una de las definiciones más citadas de una ontología es la propuesta en [23], donde se precisa que es “la especificación formal de una conceptualización compartida”. En esta definición, conceptualización hace referencia a que el conocimiento se representa utilizando conceptos, también conocidos como clases o términos principales. Los conceptos se describen en un lenguaje formal, es decir, en un lenguaje con fundamentos de lógica que se procesa en una computadora. Por otra parte, la palabra compartida, indica la existencia de un grupo de personas que usan el modelo. Una ontología se compone de clases o conceptos, instancias o elementos de las clases, reglas y relaciones entre sí. Cuando estos componentes se integran, adquieren una interpretación única para un conjunto de personas o computadoras. A manera de ejemplo, considere que la red social Facebook utiliza la ontología *Friend of a Friend* (FOAF) [15], en la cual se modelan conceptos como Persona, Perfil, Organización y Amistad. Por convención, los nombres de los conceptos se escriben con mayúscula.

Si las ontologías se asocian con un tema se denominan ontologías de dominio, y se aplican en contextos diversos como medicina, música, biología, negocios o educación.



Figura 6.3: Ejemplo de una jerarquía de clases en el editor Protégé [31]

Suponga que se desea construir una ontología que representa a una base de datos que almacena documentos elaborados en un contexto escolar. Algunos conceptos para esa ontología serían Estudiante, Documento, Profesor, Reporte y Ensayo, como se ilustra en la Figura 1. Al utilizar el editor de ontologías *Protégé*, los conceptos forman una jerarquía que a medida que se incrementa el número de niveles, los conceptos son más específicos.

La interpretación de los conceptos de la Figura 6.3 es la siguiente: los dos conceptos principales de la ontología son Documento y Persona, Estudiante y Profesor son tipos de persona; análogamente, Artículo, Ensayo y Reporte son tipos o categorías de documentos. Se emplea un rombo de color morado para los elementos de una clase o instancias, como muestra la Figura 6.4. El número entre paréntesis corresponde al número de elementos existentes por cada clase.

Las características de una clase se modelan como propiedades de datos. Ejemplos de características de un documento son el título, el tema y su fecha de elaboración; en tanto que el nombre, el apellido paterno y materno, el correo electrónico y género son características de una persona. La Figura 6.5 muestra del lado izquierdo las propiedades



Figura 6.4: Representación de instancias y clases.



Figura 6.5: Propiedades de datos para los documentos y las personas.

de datos para la clase Documento y Persona; del derecho, los valores que describen a una persona en particular. Notar que los valores están entre comillas dobles.

La relación entre cualesquiera dos instancias se modela como propiedad de objeto. Esta relación enlaza a una instancia A con una instancia B en ese sentido. La clase a la que pertenece A se denomina Dominio (en inglés *Domain*) y la clase a la que pertenece B, Rango (en inglés *Range*). La Figura 6.6 muestra, del lado izquierdo, tres propiedades de datos, así como el dominio y rango para la tercera propiedad, cuya interpretación es que una instancia de la clase Profesor revisa el documento de algún estudiante.

Las propiedades de datos, las propiedades de objeto, las definiciones de clases y sub-clases entre otros elementos de la ontología, se procesan en la computadora como un conjunto de reglas y relaciones. Una instancia, una propiedad de objeto y otra instan-



Figura 6.6: Ejemplos de propiedades de objetos, dominio y rango.

cia (que podría ser la misma), forman un enunciado o sentencia. Ejemplos de éstas se muestran en la Tabla 6.2.

Instancia	Propiedad de objeto	Instancia
Delia	revisa documento de	Araceli
Araceli	forma equipo con	Claudia
Claudia	forma equipo con	Jorge
Técnicas de aprendizaje automático	es elaborado por	Jorge

Tabla 6.2: Ejemplos de sentencias.

Los razonadores son programas de cómputo que utilizan la información representada en las ontologías para inferir. En la web semántica, inferir se refiere a la aplicación de procedimientos automáticos que generan relaciones nuevas a partir de la información existente (W3C, 2019). Por ejemplo, de la Figura 6.2, se sabe que “Jorge es profesor”, si la ontología tiene una regla que indica que “cualquier profesor es también un investigador”, entonces al usar un razonador, se obtiene que “Jorge es investigador”, la cual es una relación nueva que no formaba parte del conjunto de datos original.

Para los autores, es de interés aplicar mecanismos de inferencia a datos de repositorios, definidos en la Ley de Ciencia y Tecnología de México [19] como plataformas digitales centralizadas que, siguiendo estándares internacionales, almacenan, mantienen

y preservan la información científica, tecnológica y de innovación, la cual se deriva de investigaciones, productos educativos y académicos.

Los **repositorios institucionales** juegan un papel fundamental en la diseminación de la producción intelectual de universidades y centros de investigación bajo la filosofía de acceso abierto, (disponibilidad de contenidos, generados con recursos públicos, a través de una plataforma digital sin requerimientos de suscripción, registro o pago). Una vez establecida una política institucional de depósito de los recursos de información que reportan resultados de investigación, innovación y desarrollo tecnológico, un repositorio institucional se convierte en el mecanismo natural que presenta los avances en diversas áreas de actividad, facilita el acceso y garantiza la preservación del conocimiento.

A la fecha de elaboración de este capítulo, el Repositorio Nacional [18] (Repositorio Nacional, 2019) integra a 105 repositorios institucionales. En [28] se describe una ontología que modela conocimiento de dominio y operativo en los repositorios institucionales. Se caracteriza por hacer explícitas las relaciones entre autores y los procesos de elaboración de los documentos. Esta ontología es una alternativa para enriquecer y fomentar la reutilización de los datos, sirve como base para implementar servicios web con características semánticas.

También existen los repositorios institucionales educativos (RIE) que son medios para preservar y capitalizar el conocimiento educativo, buenas prácticas y lineamientos que genera una IES [29, 26]. La utilización de las TIC en la educación fomenta que haya un cambio en las metodologías que se emplean dentro del aula, pues se utilizan metodologías centradas en el discente, esto incentiva a que los docentes generen constantemente recursos educativos (RE) en diferentes formatos y contenidos, con el fin de hacer más dinámicos los procesos de enseñanza-aprendizaje. Sin embargo, la participación de los discentes en su propio proceso de aprendizaje tiene un impacto motivador y favorece la adquisición de conocimiento. Por lo que es preciso desarrollar en ellos habilidades de búsqueda de información de distintos RE permitiendo que el alumno sea

consciente de lo que está buscando y pueda alcanzar el conocimiento requerido [11]. Adicionalmente, debe propiciar el convertirlo en un investigador activo y creador del conocimiento [24].

6.4. Principales Desarrollos en México

6.4.1. Academia

La investigación en ontologías se ha desarrollado desde finales de los años ochenta en varias instituciones como la Universidad de las Américas de Puebla (UDLAP), el Centro de Investigación y de Estudios Avanzados del IPN (CINVESTAV), la Benemérita Universidad Autónoma de Puebla (BUAP), el Colegio de Postgraduados de Chapingo, el Centro de Investigación en Computación del Instituto Politécnico Nacional (CIC-IPN) y la Universidad Autónoma Metropolitana (UAM), entre otras.

El proceso de adquisición de conocimiento de un dominio específico realizado por los humanos es una tarea lenta, costosa y con alta probabilidad de inconsistencia. Para abordar este problema, en el CINVESTAV se han hecho propuestas para la construcción automática de ontologías a partir del análisis de grandes cantidades de texto [33]. En dicha investigación se propusieron dos modelos de aprendizaje a partir de texto proveniente de documentos no estructurados en inglés. Estos modelos se basan en *Latent Dirichlet Allocation* (LDA) [14] y la Hipótesis Distribucional [36], los cuales permiten descubrir de manera efectiva los temas cubiertos por los documentos del corpus de texto.

El enriquecimiento automático de las ontologías es un tema de creciente interés debido al enorme volumen de datos disponibles para ser incorporados como conocimiento activo en los sistemas inteligentes. En el CIC-IPN se han propuesto técnicas novedosas para adquirir nuevo conocimiento de manera incremental y automática, manteniendo la consistencia de la base de conocimientos [17]. En particular, se propuso el método

Ontology Merging [39] (OM) que incluye un algoritmo para fusionar/unir dos ontologías (obtenidas de documentos de la Web) de manera automática (sin intervención humana) para producir una tercera ontología que considere el manejo de inconsistencias y redundancias entre las ontologías originales. El uso repetido de OM permite la adquisición de mucha información del mismo tópico. Otro procedimiento para construir ontologías de manera supervisada encuentra conceptos relevantes en forma de frases temáticas y relaciones no jerárquicas en el corpus de documentos [39]. Otras aplicaciones mexicanas importantes de las ontologías incluyen:

Proyecto GeoBase, del Colegio de Postgraduados de Chapingo, cuyo objetivo es construir una base ontológica geoespacial para apoyar la investigación geomática en la gestión de recursos agrícolas y naturales [22]. Los elementos de la base de datos geoespaciales se originan del análisis de imágenes y de la manipulación de datos geográficos. Este proyecto posibilita las consultas semánticas basadas en ontologías.

Ontología para la creación del Sistema Sinóptico de Calidad Ambiental (EQSS) [16], que integra los datos requeridos a partir de sitios de Internet y datos concentrados por diferentes organismos como INEGI, CONABIO, SEMARNAT, CNA, entre otros. La ontología propuesta se basa en el conocimiento del sistema EQSS el cual posee una arquitectura similar a la de los sistemas expertos para la toma de decisiones con conocimiento sobre la calidad ambiental y la interacción con el Sistema de Información Geográfica (SIG).

Ontología genérica para video-vigilancia, que incluye los elementos visuales, objetos y acciones que son relevantes para los sistemas de video vigilancia automática [25]. Mediante la ontología se pueden realizar procesos de razonamiento para inferir situaciones de interés a partir de detecciones elementales; por ejemplo, si se detecta a una persona que lleva un objeto, lo deja y sigue caminando, se podría inferir una posible situación peligrosa al haber un objeto abandonado.

Existen también trabajos en el área de "linaje electrónico." *Electronic Provenance*. *Provenance* es una tecnología que genera los registros de las derivaciones originales de

un objeto y el paso de dicho objeto por sus diversos dueños. En términos computacionales, el linaje electrónico permite determinar el origen de un resultado computacional y la historia de los eventos que determinaron la creación de dicho resultado. Así, estos meta-datos pueden ser usados para evaluar la calidad de la información [7], atribuir el origen de un resultado computacional [9], reproducir ejecuciones previas de aplicaciones [8] o como evidencia en auditorías electrónicas [10, 10, 21]. En este sentido, una parte fundamental dentro de esta área de investigación es la generación segura del linaje electrónico de la información que será usado como evidencia electrónica [6] Si la evidencia electrónica es creada de forma confiable y segura, es posible confiar en los resultados derivados del análisis de dicha evidencia. Un ejemplo de tecnología donde la confianza es generada a través de evidencias criptográficas imposibles de ser modificadas es Blockchain [32].

También hay propuestas en el denominado 4o paradigma de la investigación científica y descubrimiento científico mediante uso intensivo de datos que consideran procesamiento inteligente de datos masivos [40]. En las e-Geociencias se consideran las ontologías y la semántica espacial como fundamento para compartir, integrar y hacer minería y análisis de datos geospaciales [42]. En México se ha abordado este tema orientado principalmente a bases de datos de imágenes satelitales. Dentro del Proyecto GeoBase CP del Colegio de Posgraduados [22] se desarrolla una aplicación cuyo objetivo es obtener una caracterización de metadatos no únicamente del ente general “imagen satelital” sino de clases y subclases que logren capturar información de procesos que se aplican a la producción de información. Estos procesos son variados y se agrupan genéricamente como flujos de trabajo o workflows. Los metadatos podrán ser transformados a una ontología que alimentará a un sistema de consulta semántica.

En cuanto a los repositorios institucionales (RI), estos surgen como una iniciativa del Consejo Nacional de Ciencia y Tecnología (CONACyT) para el acceso abierto a diversos recursos de información de índole académico, científico o tecnológico generados en instituciones públicas mexicanas. Con base a lo anterior el Repositorio Nacional del

CONACyT es una plataforma digital que proporciona el acceso abierto a dichos recursos de información a través de los repositorios institucionales sin requerimientos de suscripción, registro o pago [5, 4]. Entre los recursos disponibles podemos mencionar artículos de revistas científicas, tesis elaboradas en Instituciones de Educación Superior (IES), memorias de congresos, así como otros recursos académicos que se producen en México con fondos públicos. El CONACyT a través de sus convocatorias 2015 y 2016 para Desarrollar Repositorios Institucionales de Acceso Abierto a la Información Científica, Tecnológica y de Innovación cuenta a la fecha con 105 repositorios institucionales registrados donde podemos mencionar de la convocatoria 2016 los repositorios de la Universidad Autónoma Metropolitana en sus Unidades Iztapalapa (repositorio BINDANI [3]), Cuajimalpa y Lerma, la Universidad de las Américas Puebla, el Colegio de Posgraduados, la Universidad Politécnica de Puebla, el Instituto Tecnológico y de Estudios Superiores de Monterrey, Campus Monterrey, la Dirección General de Divulgación de la Ciencia, UNAM, por mencionar algunos. La lista de los 105 repositorios y sus 105 505 recursos de información hasta el momento disponibles se puede consultar en: [5]. Por otro lado, la Red Mexicana de Repositorios Institucionales (REMERI) es una iniciativa para integrar una red federada de repositorios de instituciones de educación superior (IES) de acceso abierto, con el objetivo de integrar, preservar y difundir la producción científica, académica y documental del país [2]. REMERI representa a México en el proyecto latinoamericano LA Referencia [1], el cual es una iniciativa en América Latina que tiene como finalidad dar visibilidad a la producción científica generada en las instituciones de nivel superior a través de una red federada de repositorios institucionales en 9 países.

Bibliografía

- [1] LA Referencia, 2016.

- [2] REMERI Red Mexicana de Repositorios Institucionales, 2016. URL <http://www.remeri.org.mx/portal/index.html>.
- [3] BINDANI (Cultivar, Cosechar y Compartir conocimiento), 2019. URL <http://bindani.izt.uam.mx:3000/?locale=es>.
- [4] Programa de Repositorios, 2019. URL <https://www.youtube.com/watch?v=vkM-BochvQs{&}feature=youtu.be>.
- [5] Repositorio Nacional, 2019. URL <https://www.repositorionacionalcti.mx/>.
- [6] R. Aldeco-Pérez and L. Moreau. *Securing provenance-based audits*, volume 6378 LNCS. 2010. ISBN 3642178189. doi: 10.1007/978-3-642-17819-1_18.
- [7] Rocio Aldeco-Perez and Miguel Leon-Chavez. Evaluar la calidad de los objetos de aprendizaje mediante linaje electrónico. 02 2013.
- [8] Rocio Aldeco-Pérez and Luc Moreau. Provenance-based Auditing of Private Data Use. In *International Academic Research Conference, Visions of Computer Science (BSC 08)*, pages 141–152, London, UK, 2008. BCS. URL <http://eprints.ecs.soton.ac.uk/16580/>.
- [9] Rocio Aldeco-Pérez and Luc Moreau. Information Accountability supported by a Provenance-based Compliance Framework. In *UK e-Science All Hands Meeting '09*, volume 1, Oxford, UK, 2009. URL <http://eprints.ecs.soton.ac.uk/18305/>.
- [10] Rocio Aldeco-Pérez and Luc Moreau. A Provenance-based Compliance Framework. In Arne J. Berre, Asunción Gómez-Pérez, Kurt Tutschku, and Dieter Fensel, editors, *Future Internet Symposium (FIS 2010)*, volume 6369, pages

- 128–137. Springer-Verlag, Berlin, Germany, Incs 6369 edition, 2010. ISBN 3-642-15876-5 978-3-642-15876-6. doi: 10.1007/978-3-642-15877-3_14. URL <http://eprints.ecs.soton.ac.uk/21437/1/FIS2010Final.pdf>.
- [11] Julio Almenara and Verónica Marín. Posibilidades educativas de las redes sociales y el trabajo en grupo. percepciones de los alumnos universitarios. *Comunicar*, pages 165–172, 01 2014.
- [12] Omar Alonso, Jaap Kamps, and Jussi Karlgren. Report on the Seventh Workshop on Exploiting Semantic Annotations in Information Retrieval (ESAIR’14). *ACM SIGIR Forum*, 49(1):27–34, jun 2015. ISSN 01635840. doi: 10.1145/2795403.2795412. URL <http://dl.acm.org/citation.cfm?doid=2795403.2795412>.
- [13] Tim Berners-Lee, James Hendler, and Ora Lassila. The Semantic Web. *Scientific American*, 284(5):34–43, may 2001. ISSN 0036-8733. doi: 10.1038/scientificamerican0501-34. URL <http://www.nature.com/doifinder/10.1038/scientificamerican0501-34>.
- [14] David M Blei, Andrew Y Ng, and Michael I Jordan. Latent Dirichlet Allocation. *Journal of Machine Learning Research*, 3(Jan):993–1022, 2003. ISSN 1533-7928. URL <http://www.jmlr.org/papers/volume3/blei03a/blei03a.pdf>.
- [15] Dan Brickley and Libby Miller. The Friend Of A Friend (FOAF) vocabulary specification, November 2007. URL <http://xmlns.com/foaf/spec/.foaf.i2cs09>.
- [16] René Cabrera-Cruz, Erika Alarcón-Ruiz, Julio Rolon, Salvador Nava-Díaz, Elena Otazo-Sánchez, and Ricardo Aviléz. Developing ontology systems as a base of an

- environmental quality management model in México. *Journal of Environmental Protection*, 06:1084–1093, 01 2015. doi: 10.4236/jep.2015.69095.
- [17] Alma Delia Cuevas and Adolfo Guzman-Arenas. Automatic fusion of knowledge stored in ontologies. *Intelligent Decision Technologies*, 4(1):5–19, 2010. ISSN 18758843. doi: 10.3233/IDT-2010-0066.
- [18] Consejo Nacional de Ciencia y Tecnología'. Repositorio nacional, October 2019. URL <https://www.repositorionacionalcti.mx>.
- [19] Diario Oficial de la Federación. Decreto por el que se reforman y adicionan diversas disposiciones de la ley de ciencia y tecnología, de la ley general de educación y de la ley orgánica del consejo nacional de ciencia y tecnología, May 2014. URL http://www.diputados.gob.mx/LeyesBiblio/ref/lct/LCT_ref08_20may14.pdf.
- [20] Tang S. Deng, Z. Ontology-based multi-agent digital library servings for information discovery on the web. 2002.
- [21] Daniel Escalante. *Auditorías electrónicas en la plataforma digital del servicio administración tributaria (SAT)*. PhD thesis, Tecnológico de Monterrey, 2017.
- [22] Yolanda M. Fernandez-Ordonez, Reyna Carolina Medina-Ramirez, and Jesus Soria-Ruiz. Geographic metadata and ontology based satellite image management. In *International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 117–120. Institute of Electrical and Electronics Engineers Inc., nov 2014. ISBN 9781479957750. doi: 10.1109/IGARSS.2014.6946370.
- [23] Thomas R. Gruber. Toward principles for the design of ontologies used for knowledge sharing. *International Journal of Human Computer Studies*, 43(5-6): 907–928, December 1995. ISSN 1071-5819. doi: 10.1006/ijhc.1995.1081. URL <https://doi.org/10.1006/ijhc.1995.1081>.

- [24] Massiel Guerra, Martin Hilbert, Valeria Jordán, and Christian Nicolai. Panorama Digital 2007 de América Latina y el Caribe Avances y desafíos de las políticas para el desarrollo con las Tecnologías de Información y Comunicaciones. Technical report. URL <http://www.cepal.org/SocInfo>.
- [25] Pablo Hernandez-Leal, Hugo Jair Escalante, and L. Enrique Sucar. Towards a generic ontology for video surveillance. In *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, volume 179 LNICST, pages 3–7. Springer Verlag, 2017. ISBN 9783319496214. doi: 10.1007/978-3-319-49622-1_1.
- [26] Victor Gallegos Cereceres E Irma Polanco Rodríguez José Alfonso Álvarez Terrazas, María Margarita Álvarez Terrazas. La importancia de los REPOSITORIOS INSTITUCIONALES PARA LA EDUCACIÓN Y LA INVESTIGACIÓN. *Synthesis*, pages 43–57, 2011. URL <http://www.uach.mx/extension{ }y{ }difusion/synthesis/2011/08/18/1a{ }importancia{ }de{ }los{ }repositorios{ }institucionales{ }para{ }1.pdf>.
- [27] X. Ma. Data repository. 2019. URL http://dx.doi.org/10.1007/978-3-319-32001-4_59-1.
- [28] María-Auxilio Medina, Alfredo Sánchez, Ofelia Cervantes, Reyna Carolina Medina, Jorge De la Calleja, and Antonio Benitez. Representación semántica de conocimiento operativo y de dominio para repositorios institucionales. Registro público del derecho de autor. Número: 03-2017- 042511235500-01. Fecha: 26 de Abril del 2017., April .
- [29] J.L. Medina-Ramírez, R.C., Galindo Durán, C.K., García-Cué. Hacia una gestión semántica masiva, abierta y vinculada de conocimiento y recursos educativos. In *Tópicos introductorios a la gestión del conocimiento*, chapter 4, pages 103–

125. Guadalajara: Ediciones de la Noche, México, 1st edition, 2016. ISBN 978-6079490348.
- [30] Diego Mendoza Vázquez. Los repositorios digitales institucionales y el acceso abierto como herramienta de difusión de contenidos académicos. 2017. URL goo.gl/ZZvL3p.
- [31] Mark A. Musen. The protÉgÉ project: a look back and a look forward. *AI Matters*, 1(4):4–12, June 2015. ISSN 2372-3483. doi: 10.1145/2757001.2757003. URL <http://doi.acm.org/10.1145/2757001.2757003>.
- [32] Satoshi Nakamoto. Bitcoin: A peer-to-peer electronic cash system. *Cryptography Mailing list at https://metzdowd.com*, 03 2009.
- [33] Isidra Ocampo-Guzman, Ivan Lopez-Arevalo, and Victor Sosa-Sosa. Data-driven approach for ontology learning. In *2009 6th International Conference on Electrical Engineering, Computing Science and Automatic Control, CCE 2009*, 2009. ISBN 9781424446896. doi: 10.1109/ICEEE.2009.5393402.
- [34] Adrian Paschke. Corporate Semantic Web, 2013. URL <http://www.corporate-semantic-web.de/>.
- [35] Woroniecki Tomasz Gzella Adam. Dabrowski Maciej Ryszard Kruk, Sebastian. Jeromedl a semantic digital library. 2007.
- [36] Magnus Sahlgren. The distributional hypothesis. *Italian Journal of Linguistics*, 20, 01 2008.
- [37] N. Semple. Repositorios digitales. 2006. URL <http://www.dcc.ac.uk/resources/briefing-papers/introduction-curation>.
- [38] Leslie F Sikos. Mastering Structured Data on the Semantic Web: From HTML5 Microdata to Linked Open Data. 2005.

- [39] A.Martínez-Luna G. L. Toledo-Alvarado, J. I.Guzmán-Arenas. Automatic building of an ontology from a corpus of text documents using data mining tools. *Journal of Applied Research and Technology*, 2012. ISSN 1665-6423. URL <https://www.redalyc.org/articulo.oa?id=47423208009>.
- [40] K.M. Tolle, Stewart Tansley, and Tony Hey. The fourth paradigm: Data-intensive scientific discovery [point of view]. *Proceedings of the IEEE*, 99:1334–1337, 08 2011. doi: 10.1109/JPROC.2011.2155130.
- [41] Peter C. Weinstein and William P. Birmingham. Creating ontological metadata for digital library content and services. *International Journal on Digital Libraries*, 2(1):20–37, oct 1998. ISSN 14325012. doi: 10.1007/s007990050034. URL <http://link.springer.com/10.1007/s007990050034>.
- [42] Yunqiang Zhu, Peng Pan, Shifeng Fang, Li Xu, Jia Song, Jinqiu Zhang, and Min Feng. The development and application of e-geoscience in china. *Information Systems Frontiers*, 18(6):1217–1231, December 2016. ISSN 1387-3326. doi: 10.1007/s10796-015-9571-4. URL <https://doi.org/10.1007/s10796-015-9571-4>.

Capítulo 7

Ciencia y Analítica de Datos

Gerardo Abel Laguna Sánchez

Universidad Autónoma Metropolitana,

Rosa María Valdovinos Rosas

Universidad Autónoma del Estado de México

7.1. Introducción

En nuestros días es notable el fenómeno de la omnipresencia de datos en todos los ámbitos del quehacer humano y, por su puesto, en el de las organizaciones. La tecnología actual ha hecho posible el disponer de grandes cantidades de información, provenientes tanto del entorno de las organizaciones como del interior de las mismas.

En este contexto, el concepto de minería de datos se ha reformulado para crear métodos que permitan la extracción de información útil y generación de nuevo conocimiento, todo ello a partir de los datos disponibles en grandes volúmenes y con diversos formatos.

Aunque originalmente la minería de datos fue un proceso computacional que empleaba la totalidad de los datos disponibles y las capacidades de pronóstico de los algo-

ritmos del aprendizaje máquina, para descubrir patrones en conjuntos de datos típicamente estructurados, actualmente la Ciencia de Datos hace énfasis en el procesamiento de muestras con sólo una parte del total de los datos disponibles, dado que normalmente se trata de cantidades enormes de datos que, además, pueden ser tanto estructurados como no estructurados. Lo ideal en estos casos es que las muestras de datos sean estadísticamente representativas.

Por lo antes mencionado, es común encontrar que la Ciencia de Datos se relaciona con varios de los siguientes conceptos.

Datos masivos (*Big Data*) Se refiere a grandes volúmenes de datos, con diferentes formatos, que fluyen a muy distintas velocidades y que representan diferentes niveles de utilidad.

Aprendizaje de máquina (*Machine Learning*) Son las técnicas y los algoritmos de la inteligencia artificial que sirven para crear modelos que permiten el pronóstico de variables, todo esto con base en un conjunto de datos destinados para el “entrenamiento” o “aprendizaje” del modelo desarrollado.

Análítica de datos Es la aplicación de la tecnología al análisis de datos, sobre todo, para la extracción automática de aquellas relaciones que no son evidentes en un conjunto de datos.

Análisis de datos Es la actividad que realiza una persona para extraer conclusiones relevantes a partir de un conjunto de datos.

Así, el concepto de Ciencia de Datos, involucra principios, procesos y técnicas para comprender los fenómenos observados mediante el análisis automático de un conjunto de datos. En particular, respecto de los principios, podemos decir que estos principios orientan la extracción de conocimiento de los datos y son conceptos fundamentales y perdurables, con independencia de las tecnologías disponibles para desarrollar esta actividad. Algunos de estos principios son los siguientes:

- Deben considerarse activos estratégicos de la organización tanto a los datos como a la capacidad para extraer información útil de los mismos.
- La extracción de información útil de los datos, particularmente para la resolución de problemas en las organizaciones, puede ser manejada sistemáticamente mediante las etapas bien definidas del proceso de minería de datos.
- El equipo de diseño debe analizar cuidadosamente el problema a resolver, así como el ámbito de la aplicación, todo ello mediante el proceso de minería de datos.
- La formulación y evaluación de soluciones mediante la analítica de datos involucra un estudio detallado del contexto en el que se usará la información obtenida.
- Partiendo de un gran conjunto de datos, es posible usar la tecnología de la información disponible para descubrir atributos descriptivos con información de utilidad para los usuarios interesados.
- Si se analiza con exceso un conjunto de datos, se puede encontrar una regla, sin embargo, esta regla no permitirá generalizar más allá del conjunto de datos observado.

En el contexto planteado por estos principios, la minería de datos se reformula como el proceso de extracción de conocimiento de los datos, mediante la tecnología vigente, que aplica los principios de la ciencia de datos. En otras palabras, la minería de datos renovada no sólo aplica la tecnología disponible en el desarrollo de sus actividades, sino que además aplica los principios que enuncia la ciencia de datos. Esto implica que aunque la tecnología puede cambiar, los principios de la ciencia de datos siempre se mantendrán vigentes.

Entre las aplicaciones más emblemáticas de la ciencia de datos, en el marco de la minería de datos, se encuentran el pronóstico para el consumo de ciertos productos,

la prevención de la deserción de clientes, la detección de operaciones fraudulentas, así como las recomendaciones y la publicidad personalizada. Como podemos comprobar, una motivación constante en el ejercicio profesional del científico de datos es el de poder realizar pronósticos a partir de muestras de datos. En este punto, es conveniente aclarar que los métodos predictivos, sustentados en un conjunto de datos, se han desarrollado principalmente en tres disciplinas: (1) El aprendizaje de máquina, (2) La estadística aplicada y (3) El reconocimiento de patrones.

Aquí, es importante recordar que el aprendizaje máquina es un sub-campo de la IA que se enfoca en el mejoramiento del aprendizaje de agentes, con base en la experiencia de los mismos a lo largo del tiempo. En este sentido, aunque el análisis de datos y el pronóstico de variables se han vuelto actividades predominantes dentro del aprendizaje máquina, no debemos perder de vista que esta disciplina abarca aspectos como robótica y visión por computadora, mientras que la minería de datos, y por lo tanto la ciencia de datos, se enfoca principalmente en aplicaciones del ámbito comercial y de los negocios.

7.2. La minería de datos como disciplina científica

Hoy vivimos lo que se ha denominado como la “Era de la Información”. Ya comentamos que la generación y adquisición de datos en diferentes ámbitos de la vida cotidiana, comerciales, transaccionales, científicas, sociales y casi de cualquier índole, crece a un ritmo extraordinario. Esta situación es la causa de que hayan sido rebasados los límites de aplicación de los métodos del análisis estadístico convencional. La mayoría de los avances para abordar este problema se orientan más a la obtención de grandes medios de almacenamiento de la información que a la realización del adecuado análisis de ésta, sin embargo, la Ciencia de Datos se encarga de aplicar algoritmos a los bancos de datos para extraer conocimiento no explícito y útil. De forma específica, el proceso de la Minería de datos es clave para ese cometido.

La minería de datos, también es conocida como minería de conocimiento en base de datos, descubrimiento de conocimiento en bases de datos, extracción de conocimiento, análisis de datos y patrones, arqueología de datos, entre otras. En la literatura se han dado muchas definiciones para la minería de datos, no obstante, todas ellas coinciden en varios aspectos definitorios: es la exploración y análisis de grandes cantidades de datos con el objeto de encontrar información valiosa en forma de patrones, asociaciones y reglas significativas (conocimiento), previamente desconocidas. Además, para que este proceso sea efectivo deberá ser automático o semiautomático (asistido) y el uso de la información descubierta deberá ayudar a la toma de decisiones.

Aunque diversos esquemas han sido propuestos para realizar el proceso de minería de datos, predominan tres: el KDD (*Knowledge Discovery in Databases*), el SEMMA (*Sample, Explore, Modify, Model, Assess*) y el muy conocido CRISP-DM (*Cross Industry Standard Process for Data Mining*) [1]. Cada uno de estos esquemas puede variar en las etapas que lo conforman, no obstante, en términos generales y en esencia, todos contemplan las siguientes etapas: la determinación de la fuente de los datos, el pre-procesado de datos (preparación, limpieza y transformación de datos), el algoritmo de minería de datos y el método de evaluación e interpretación de los resultados [2]. De las diferentes etapas, la más costosa es la relacionada al pre-procesado de los datos, la cual se ha considerado que constituye hasta el 70 % del proceso global de minería de datos. Este elevado costo obedece al hecho de que los datos, sin distinción de la fuente de procedencia, normalmente no se encuentran listos para su procesamiento y se consideran como “sucios”, por lo que requieren de ser tratados de tal forma que su calidad permita garantizar el resultado esperado.

Los datos, con los que se realiza el proceso de minería de datos, pueden provenir de fuentes muy variadas y el costo de adquisición puede ser muy alto en términos de tiempo y dinero. Por ello, para realizar investigaciones en el campo de la minería de datos comúnmente se recurre a repositorios con datos públicos, algunos de los más utilizados son [3]:

- Repositorio de Aprendizaje Automático de la Universidad de California¹
- UCI KDD²
- Repositorio Delve³
- Proyecto Open ML⁴
- Repositorio Golem⁵
- Repositorio de la Universidad de Liverpool⁶
- KEEL-dataset⁷

Respecto de la preparación de los datos, es importante reconocer y tratar los diferentes problemas que presentan los datos y que, de alguna forma, deterioran el rendimiento del modelo que se crea con ellos. A estas problemáticas se les conoce como la complejidad de datos. Las complejidades más importantes o de mayor impacto son:

1. Datos faltantes o perdidos. La pérdida de información puede deberse a dos circunstancias principalmente se puede tratar de un dato que se omitió o que, debiendo haber sido registrado, se registró de forma errónea.
2. Patrones atípicos y *Outliers*. Se trata de un problema que pudiera ser derivado, no sólo de la integración del conjunto de datos, sino que puede estar asociado a la naturaleza del caso de estudio. Por un lado, los patrones atípicos son aquellos que, a pesar de pertenecer a una clase, son significativamente diferentes del

¹<http://archive.ics.uci.edu/ml/index.php>

²<http://kdd.ics.uci.edu>

³<http://www.cs.toronto.edu/delve/data/datasets.html>

⁴<https://www.openml.org>

⁵<http://www.cs.ox.ac.uk/activities/machinelearning/applications.html>

⁶<http://cgi.csc.liv.ac.uk/%2ofrans/KDD/Software/LUCS-KDD->

[DN/DataSets/dataSets.html#datasets](http://www.keel.es)

⁷<http://www.keel.es>

resto de los patrones de su misma clase. Por otro lado, los *outliers* son datos cuyas características difieren significativamente del resto de los patrones de su clase, tratándose de muchas veces de casos raros o poco frecuentes.

3. Desbalance de clases. Es uno de los problemas más frecuentes de encontrar en datos reales. Se dice que existe desbalance de clases cuando una o varias de las clases son menos representadas con respecto al número de patrones pertenecientes a otras clases.
4. Traslape de clases. Este problema se presenta cuando los datos tienen atributos poco discriminantes, de tal manera que patrones pertenecientes a diferentes clases comparten información en común en algunos de sus atributos.
5. Alta dimensionalidad. Este problema se caracteriza por tener un elevado número de atributos, que puede llegar a ser superior respecto a la cantidad de patrones de los que se dispone.

Respecto de las técnicas usadas por la minería de datos, la clasificación más aceptada en la literatura es la que se realiza en función del objetivo que se persigue. Existen dos grandes grupos: las técnicas descriptivas y las técnicas predictivas. Las técnicas descriptivas son aquellas que parten del banco de datos y construyen un modelo que representa el comportamiento general de los datos. Algunos de los algoritmos que siguen este tipo de objetivo son los de agrupamiento, las reglas de asociación y el descubrimiento de patrones secuenciales. Por otro lado, las técnicas predictivas son aquellas que construyen un modelo que, con base al histórico de información disponible, tengan la capacidad de pronosticar los valores futuros o desconocidos. Ejemplo de algoritmos de este tipo son los de clasificación y regresión. Actualmente es posible encontrar repositorios con herramientas de software que cuentan con los algoritmos más utilizados en la mine-

ría de datos. Algunos ejemplos de estas herramientas son [3]: WEKA⁸, SPSS⁹, KEEL¹⁰, RapidMiner¹¹, Proyecto¹², TANAGRA¹³, ADaM¹⁴.

Con excepción de SPSS y RapidMiner, las demás herramientas son de acceso abierto y, entre otros atractivos, permiten la descarga del código en lenguajes como Java, Python, C y C++. Esto posibilita al interesado para aprovechar los experimentos disponibles en desarrollos propios. En el caso que los algoritmos disponibles en estos repositorios no fueran suficientes para nuestros procesos de minería de datos, también existen otros entornos de trabajo de acceso abierto, por ejemplo, los desarrollados para atender necesidades propias del *Big Data* que ofrecen procesamiento en línea y distribuido [3]. Algunos ejemplos de estos entornos son Spark¹⁵, Hadoop¹⁶, Flink¹⁷ y Mahout¹⁸, como fueron descritos en el Capítulo 4.

La mayoría de los entornos utilizan como base la programación en Java y Python, además de contar con bibliotecas útiles para el proceso de la minería de datos. Para concluir con esta sección, mencionaremos que la tendencia actual en el estudio de la minería de datos puede verse desde dos perspectivas: una orientada al escalado de los algoritmos y la otra orientada a la optimización de los recursos computacionales para atender las demandas de análisis de datos más complejas. Respecto de la escalabilidad de los algoritmos podemos decir que, particularmente con la aparición del concepto *Big Data*, surgen nuevas oportunidades para los algoritmos de la minería de datos. Recordemos que el *Big Data* se enfoca en grandes volúmenes de datos que, adicionalmente, cuentan con

⁸<https://www.cs.waikato.ac.nz/ml/weka/>

⁹<https://www.ibm.com/mx-es/marketplace/spss-modeler/details>

¹⁰<http://www.keelframework.org/contributors.shtml>

¹¹<https://rapidminer.com/get-started/>

¹²<https://www.r-project.org>

¹³<http://eric.univ-lyon2.fr/ricco/tanagra/en/tanagra.html>

¹⁴<http://projects.itsc.uah.edu/datamining/adam/>

¹⁵<https://spark.apache.org/mllib/>

¹⁶<https://hadoop.apache.org>

¹⁷<https://flink.apache.org>

¹⁸<https://mahout.apache.org>

características que la minería de datos tradicional no consideraba. Las nuevas características de los datos en grandes volúmenes incluyen a) la diversidad de formato a procesar, dado que, en un momento dado, provenientes de muy distintas fuentes (social media, tweets, correos, información de sensores, multimedia, datos relacionales complejos); b) la velocidad del flujo de los datos, con variaciones en tiempos de llegada y c) una mayor demanda de capacidad de procesamiento, esto debido al gran volumen de datos que hay que procesar en periodos cortos para cumplir con los requisitos del procesamiento en tiempo real. Entre los temas de escalabilidad también está la minería con flujos de datos de alta velocidad y posibles cambios de estructura y dimensión. Incluso, se prevé la necesidad de modelos de generación dinámica durante la fase de entrenamiento. En estos escenarios, el objetivo que se persigue es que los algoritmos tengan un funcionamiento estable ante cualquier variación que presenten los datos. Finalmente, respecto de la optimización de los recursos computacionales, mencionaremos que, a fin de enfrentar la demanda cada vez más creciente del volumen de datos, se requiere que el procesamiento de los datos se realice con rapidez, optimizando los recursos computacionales disponibles. Para ello, puede ser de ayuda la paralelización de los procesos y el procesamiento distribuido e incremental de los algoritmos funcionando en tiempo real.

Una consideración importante, durante el proceso de optimización de los recursos, es que las mejoras que se realicen a los algoritmos deben garantizar tolerancia a fallos y ser eficientes en su procesamiento sin sacrificar precisión en el resultado.

Podemos concluir esta sección recordando que la minería de datos es un área del conocimiento que se ha consolidado ampliamente para brindar soluciones a problemas de la vida real, sin embargo, hoy día es un campo de estudio científico con grandes expectativas y retos en el contexto que plantea la ciencia de datos y el *Big Data*. Es evidente que el vertiginoso desarrollo tecnológico y la explosión en la generación de datos en diversos ámbitos de la vida cotidiana, brindan nichos de oportunidad que demandarán la continuidad en el desarrollo de nuevos métodos y la adaptación a la demanda actual de



Figura 7.1: Etapa de aprendizaje en el desarrollo de un modelo a partir de datos.

muchos de los ya existentes, por lo tanto, esta es un área de gran interés y desarrollo en el ámbito de las ciencias computacionales.

7.3. De la generación de un modelo a su aplicación

El equipo de diseño que aplica los principios de la ciencia de datos, en realidad, realiza un trabajo conjunto de investigación y desarrollo, es decir, de generación de conocimiento y de aplicación del mismo, independientemente de que se les llame “científicos de datos”. El desarrollo y aplicación de un modelo se puede dividir en tres etapas muy claras que a continuación se describen.

Etapas de aprendizaje. Esta es la etapa de generación de un modelo mediante un proceso inductivo, es decir, se parte de casos particulares para obtener una descripción general. El trabajo inicia con un conjunto de datos históricos. De estos datos históricos, se elige una muestra estadísticamente significativa que se empleará como muestra de entrenamiento. Es entonces que, con el proceso de minería de datos y las herramientas del aprendizaje máquina, se genera un modelo de pronóstico que puede verse como un generador de hipótesis, es decir un modelo que en cada consulta responde con una afirmación sujeta de ser verificada. En esta etapa, el objetivo es que el modelo arroje hipótesis que concuerden, mayoritariamente, con las observaciones presentes en la muestra de entrenamiento.

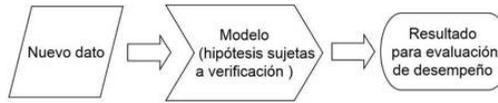


Figura 7.2: Etapa de validación en el desarrollo de un modelo a partir de datos.

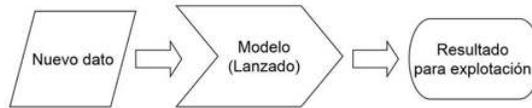


Figura 7.3: Etapa de explotación de un modelo a partir de datos.

Etapa de validación. En esta etapa se comprueba la capacidad de generalización del modelo. Se usan datos históricos, que no formaron parte de la muestra de entrenamiento, para probar la capacidad de acierto del modelo con datos nuevos. En este caso el modelo genera hipótesis para las observaciones que reservamos con fines de validación. Es importante recalcar que la muestra de validación es diferente a la muestra de entrenamiento. La etapa de validación es iterativa y termina cuando el equipo de diseño considera que el modelo ha demostrado, con suficiencia, su capacidad para generalizar, es decir, su capacidad para acertar en las hipótesis para datos que no formaron parte de la muestra de entrenamiento.

Etapa de explotación. En esta etapa se realiza el lanzamiento del modelo generado y se aplica a datos realmente nuevos, de los que se desconoce el valor que se pronostica. En este caso, se trata de un proceso deductivo que parte de una descripción general para determinar casos particulares.

Estas etapas de aprendizaje, verificación y explotación, a su vez, coinciden con las etapas de modelado, evaluación y lanzamiento del proceso iterativo, de la minería de datos, conocido como *Cross Industry Standard Process for Data Mining* (CRISP). En la figura 7.4 puede observar el proceso iterativo CRISP de la minería de datos. Nótese

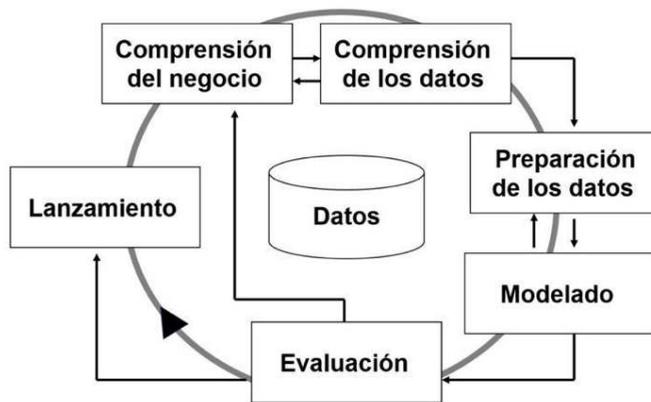


Figura 7.4: Proceso iterativo CRISP de la minería de datos.

que las etapas de comprensión del negocio y de los datos son fundamentales antes de proceder con la etapa de modelado, lo que es completamente compatible con los principios de la ciencia de datos, sobre todo en cuanto al análisis del ámbito y contexto en el que se usará la información generada. Por lo demás, también nótese que el proceso CRISP es iterativo ya que, durante las etapas de investigación y desarrollo, siempre es posible mejorar o ajustar el modelo que representa a los datos. Por último, es importante mencionar que el ejercicio profesional de la ciencia de datos requiere que el equipo de diseño cuente con habilidades que van más allá de la simple programación: se deben formular correctamente los problemas; se deben desarrollar rápidamente prototipos de solución; se deben proponer supuestos razonables para datos poco estructurados; se deben proponer experimentos que muestren los efectos en la rentabilidad y, finalmente, hay que ser capaces de analizar los resultados obtenidos.

7.4. Las herramientas de la analítica de datos

La etapa de investigación, que genera un modelo para un problema dado, implica la división del mismo en problemas más pequeños, que pueden ser resueltos por herramientas bien conocidas de la analítica de datos, y finalmente integrarlos en una solución. Entre otras, algunas de las herramientas canónicas que emplea la analítica de datos, y que provienen de las disciplinas del aprendizaje maquina y del reconocimiento de patrones, son particularmente útiles para la ciencia de datos. A continuación presentamos una lista y una pequeña descripción de dichas herramientas. Su descripción detallada puede encontrarse en otros de los libros editados por la Academia Mexicana de la Computación.

Clasificación Su propósito es determinar a qué conjunto o clase pertenece un individuo. La clasificación está íntimamente relacionada con el ordenamiento (*scoring*). Por ejemplo, una herramienta de clasificación permitiría responder a la pregunta ¿Qué individuo responderá a una oferta?

Regresión Su propósito es estimar o pronosticar el valor de alguna variable para cierto individuo. Por ejemplo, una herramienta de regresión permitiría responder a la pregunta ¿Cuánto comprará un individuo? Es importante aclarar que, más que de describir los individuos que ya existen, se trata de pronosticar características para los que no se encuentran en el conjunto [4, 5].

Empate por similitud Su propósito es identificar individuos similares. Por ejemplo, una herramienta de empate por similitud permitiría responder a la pregunta ¿Qué individuos tienen los mismos hábitos de consumo?

Agrupamiento (*clustering*) Su propósito es agrupar individuos de acuerdo a su similitud. Por ejemplo, una herramienta de agrupamiento permitiría responder a la pregunta ¿Qué individuos forman un segmento del mercado?

Agrupamiento por co-ocurrencia Su propósito es encontrar asociaciones entre entidades con base en las transacciones en las que participan. Por ejemplo, una he-

herramienta de agrupamiento por co-ocurrencia permitiría responder a la pregunta ¿Qué productos se compran juntos?

Perfilamiento Su propósito es caracterizar los hábitos de individuos o grupos de individuos. Por ejemplo, una herramienta de perfilamiento permitiría responder a la pregunta ¿Cuál es el uso del teléfono celular para un segmento del mercado?

Predicción de relaciones Su propósito es pronosticar conexiones entre individuos y la fuerza de la conexión. Por ejemplo, podríamos inferir que si dos individuos comparten amigos, entonces, tal vez ambos deseen conocerse.

Reducción de datos Su propósito es representar un gran conjunto de datos por otro, más pequeño, que contiene la mayoría de la información relevante.

Modelación causal Su propósito es encontrar relaciones de causa y efecto. Por ejemplo, una herramienta de modelación causal permitiría responder a la pregunta ¿Un individuo compró porque lo motivó un anuncio o simplemente lo iba a comprar de cualquier forma?

Como ya se mencionó, la ciencia de datos se apoya en el proceso de la minería de datos que, a su vez, emplea las herramientas canónicas de la analítica de datos para la etapa de aprendizaje o modelación. En particular, existen dos enfoques en los que cada una de estas herramientas puede contribuir. El primero es el aprendizaje supervisado en donde el programador proporciona la información del objetivo que se persigue, junto con ejemplos que lo ilustran. Algunos problemas que pueden resolverse con aprendizaje supervisado son los relacionados con las preguntas ¿Se contratará el servicio S si se recibe el estímulo X? (clasificación binaria), ¿Qué servicio se contratará (S_1 , S_2 , o ninguno)? (clasificación) y ¿Cuánto se usará el servicio? (regresión). El segundo es el aprendizaje no supervisado donde el programa, por sí solo, agrupa a los individuos por similitud, con base en los ejemplos que se proporcionan, pero sin que el programador proporcione

información del objetivo que se persigue. Típicamente, este tipo de aprendizaje incluye a las técnicas de agrupamiento, agrupamiento por co-ocurrencia y perfilamiento.

Es importante comentar que algunas técnicas pueden ser tanto supervisadas como no supervisadas. Por ejemplo, las técnicas de empare de similitudes, de predicción de relaciones y de reducción de datos pueden emplearse tanto para aprendizaje supervisado como no supervisado.

La ciencia de datos también emplea técnicas y tecnologías derivadas de otras disciplinas como, por ejemplo, de la teoría estadística y del campo del *Big Data* [6]. Es particularmente importante la teoría estadística, ya que la analítica de datos a partir de muestras representativas está soportada por ella. Por ejemplo, la teoría estadística permite realizar pruebas de hipótesis y estimar el grado de incertidumbre de las conclusiones. Finalmente, tecnologías subyacentes al desarrollo de los proyectos de ciencia y analítica de datos son las peticiones realizadas a las bases de datos, estructuradas y no estructuradas, así como la infraestructura tecnológica (*data warehousing*) para recolectar y concentrar los datos de una organización.

7.5. Principios de modelación

Un modelo es una representación simplificada de la realidad que se crea para un propósito dado. El modelo implica un proceso de abstracción, donde se omiten detalles irrelevantes para el propósito del modelo. Recordemos también que la creación de un modelo a partir de datos es un proceso de inducción, mientras que el empleo del modelo desarrollado, alimentándolo con datos históricos o nuevos, es un proceso de deducción.

Ya se ha mencionado antes que, en la ciencia y la analítica de datos, la capacidad para realizar pronósticos tiene un papel preponderante, por lo tanto, los modelos para pronóstico son especialmente utilizados. De nueva cuenta, recordemos que en la ciencia de datos lo importante es estimar la variable desconocida, sin importar si el evento relacionado se encuentra en un tiempo pasado, presente o futuro. Más bien, se trata

de acertar en la caracterización de un nuevo elemento o individuo. Comúnmente, un modelo para pronóstico es una función, que puede ser matemática, lógica, o una mezcla, para la estimación de una variable desconocida. La variable incógnita es lo que se denomina "variable objetivo." o simplemente "variable de interés".

Por su parte, los datos, alrededor de los que gira todo el proceso de la minería de datos y que constituyen los insumos de la ciencia y analítica de datos, reciben diversas denominaciones según la disciplina de la que son objeto de estudio. Por ejemplo, se les puede llamar ejemplos o instancias, incluso renglones en una base de datos o casos en un experimento estadístico. En cualquier caso, se trata de un conjunto de datos históricos que pueden concebirse como tuplas (vectores) de propiedades (parejas atributo-valor), es decir, variables (o características) con sus respectivos valores.

Respecto del espacio de representación de las instancias de un conjunto de datos, podemos decir que se encuentran alojadas en un espacio de tantas dimensiones como el número de los atributos que caracterizan a las mismas. Por ejemplo, las instancias con dos atributos se pueden representar en un plano, mientras que las instancias de tres atributos se pueden representar en un volumen. De manera concordante, en un plano se puede realizar la clasificación de los datos mediante líneas que funcionan como fronteras, mientras que en un volumen las fronteras son superficies.

En este punto es importante reconocer que, normalmente, de todas las variables del vector con el que representa a las instancias de un conjunto, sólo algunas de ellas son relevantes para el modelo que las representa. En este sentido, se denominan como variables significativas a aquellas que aportan información útil para mejorar el desempeño de un modelo. Con ello, se entiende que la información es un valor que reduce la incertidumbre sobre algo.

Precisamente, partiendo de la Teoría de la Información de Shannon, dentro de la analítica de datos, también se le emplea el concepto de entropía para determinar cuán significativas son las variables que caracterizan a un conjunto de instancias o individuos.

De acuerdo a esta teoría una medida de la información de un sistema está dada por:

$$\text{entropía} = - \sum_i p_i \log(p_i)$$

Donde p_i es la probabilidad de la aparición, dentro del conjunto de datos, de la variable de interés con un cierto valor o característica. Por ejemplo, si todos los miembros de un conjunto presentan la variable de interés con el valor o característica i , entonces $p_i = 1$.

Se dice que la entropía de un conjunto de datos es menor en tanto se vuelve más homogéneo (más predecible). Por el contrario, la entropía aumenta en tanto el conjunto se vuelve menos homogéneo (menos predecible). Baste decir, para propósitos de este capítulo introductorio, que si definimos umbrales para cada una de las variables que los caracterizan y segmentamos el conjunto a partir de cada uno de estos umbrales, la homogeneidad de los subconjuntos resultantes se puede determinar mediante el concepto de entropía, en forma cuantitativa y objetiva, lo que, a su vez, permite determinar cuáles son las variables significativas para un modelo dado.

En particular, existe una técnica que se conoce como árbol de clasificación, en la que se toman cada una de las variables significativas, una a la vez, y se define un umbral para determinar si una instancia es de una clase o no, dependiendo de si el valor observado está por debajo o por encima del umbral especificado. Como se va iterando una decisión por cada una de las variables, en esta técnica de clasificación se van generando fronteras que son perpendiculares a los ejes de las variables consideradas.

Así, un árbol de decisión pertenece a la clase de modelos que emplean funciones lógicas para representar a las instancias de un conjunto. Sin embargo, también existen modelos paramétricos en los que se usan todas las variables involucradas en una misma función y, por lo tanto, la frontera resultante normalmente no es perpendicular a los ejes de las variables consideradas.

7.5.1. Modelación paramétrica

La modelación paramétrica produce una estructura matemática para el modelo (una función en términos de las variables o atributos) y trata de ajustar los parámetros (por ejemplo, los pesos de cada variable) de tal forma que el modelo empata con los datos con un mínimo de error. Las funciones más sencillas son las lineales y son el fundamento para técnicas como la regresión lineal de la estadística, además de corresponder a fronteras que necesariamente son líneas, planos o hiperplanos en el espacio de las instancias. Entonces, la estructura general para un modelo lineal se puede expresar como:

$$f(x) = w_0 + w_1x_1 + w_2x_2 + \dots$$

Tomemos, por ejemplo, el caso donde deseamos clasificar un conjunto de instancias que sólo pueden ser de dos tipos (problema de clasificación binaria), de tal manera que una instancia o individuo puede ser del tipo A o tipo B. En particular, estas instancias se caracterizan por vectores de dos variables (digamos, edad e ingresos), de tal forma que el espacio de las instancias es un plano. Entonces, podemos tener un escenario como el de la figura 7.5. Podemos preguntarnos, para este ejemplo, ¿Cuál es la mejor función lineal, que segmenta el espacio de las instancias, de tal forma que resultan dos subconjuntos con la mayor homogeneidad posible? Como se puede observar en la figura 7.6, el número de posibles soluciones es infinito. Entonces, normalmente se recurre a criterios para optar por alguna de las posibles soluciones. Estos criterios, a su vez, se relacionan dentro de una función objetivo que debe ser maximizada o minimizada. La solución que optimiza el máximo o el mínimo, en la función objetivo asociada, es la que se elige como la mejor solución. Existen muchos criterios de optimización y todos resultan en soluciones factibles. Uno de los criterios más utilizado es el de la suma de los errores. Con el criterio de la suma de errores, el modelo que mejor empata con los datos es aquel donde la suma de los errores es mínima. En nuestro ejemplo, el error significaría que, dada una función de segmentación, una instancia o individuo quedara en el lado incorrecto de la frontera que separa al tipo A del tipo B. También podemos comprobar en

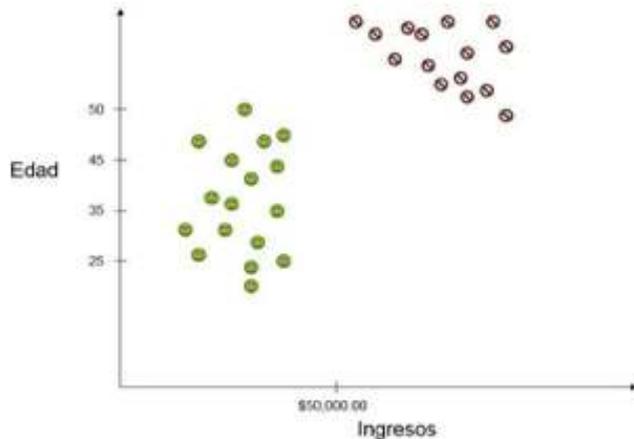


Figura 7.5: Espacio de las instancias del tipo A y B.

la figura 7.6, que sólo criterio del error no es suficiente para optar por alguna de las posibles soluciones, por ello se incorporan otros criterios como, por ejemplo, pudiera ser el de la distancia mínima promedio entre los individuos de cada clase y la frontera que los separa. Es importante hacer notar que cada técnica de modelación tiene su función objetivo, con ventajas y desventajas.

Aquí, el hecho relevante no es que el modelo propuesto separe en forma perfecta a los miembros de la muestra que usamos para generar el modelo (muestra de entrenamiento), sino que el modelo separe correctamente a nuevas instancias, minimizando con ello al error. Se dice que, en la medida que el modelo funcione bien con las nuevas instancias, el modelo tiene mejor capacidad para generalizar. Como veremos después, un modelo puede funcionar perfectamente (sin errores) para las muestras de entrenamiento pero puede funcionar mal con las nuevas. En este caso, se dice que existe un exceso de ajuste (*overfitting*) que debe ser relajado, para permitir que el modelo aumente su capacidad de generalización (de pronóstico) y acierte para las nuevas instancias, aun-

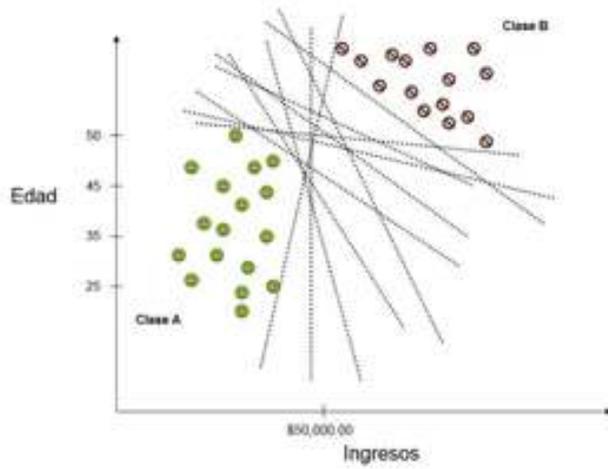


Figura 7.6: Algunas funciones lineales para clasificar las instancias del tipo A y B.

que ello pudiera implicar que presente algunos errores con las instancias de la muestra de entrenamiento. Entonces, no sólo se trata de validar el modelo con los datos conocidos sino, más importante aún, de maximizar su capacidad de predicción con exactitud.

En el caso de nuestro ejemplo, existe una posibilidad interesante de solución para la clasificación de las instancias. Supongamos que escogemos la función que representa a la línea con el mayor ancho posible (máximo margen), como se muestra en la figura 7.7. Entonces, con este criterio, podemos clasificar sin error a las muestras de entrenamiento, al mismo tiempo que obtenemos una frontera que segmenta el espacio y que, presumiblemente, tiene buena capacidad de generalización. Esta es, precisamente, la idea detrás de la técnica de máquinas de soporte vectorial.

Dada la relativa simplicidad de los modelos lineales, es común intentar aplicarlos, hasta donde es posible, en algunas relaciones que tienen comportamientos no lineales pero que muestran comportamientos cuasi-lineales en ciertos intervalos. Por ejemplo, la técnica conocida como regresión logística, emplea esta idea para la estimación de probabilidades.

Los mismos principios expuestos también se pueden aplicar a modelos no lineales. De hecho, existen versiones no lineales para las técnicas de regresión logística y de máquinas de soporte vectorial. También existen técnicas y heurísticas bio-inspiradas para abordar problemas no lineales. Una técnica que es particularmente útil para modelar procesos no lineales es la soportada por redes neuronales [8].

Las diferentes técnicas que caracterizan a un conjunto de instancias llegan a resultados similares, aunque por diferentes rutas y supuestos. Más aún, estrictamente hablando, la mejor alternativa no es tanto aquella con el menor error respecto de los datos existentes, sino más bien respecto del acierto en las estimaciones de los datos no conocidos.

Es importante mencionar que para la etapa de aprendizaje existen muchas técnicas y algoritmos que no son descritos en este libro a detalle por no pertenecer al área de representación de conocimiento, si no a la de aprendizaje. Sin embargo, si el lector esta

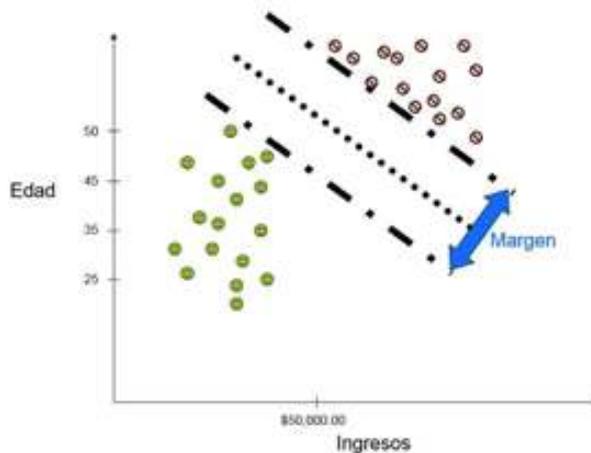


Figura 7.7: Solución para un clasificador que maximiza el margen de una función lineal.

interesado en esta área lo referimos al libro “Aprendizaje e Inteligencia Computacional” editado por la Academia Mexicana de la Computación.

7.6. Conclusión

Los problemas de los negocios no son, en sí mismos, problemas de clasificación, regresión o agrupamiento, son simplemente problemas que hay que resolver. El equipo que diseña una solución puede usar las herramientas de la analítica de datos, pero también debe considerar las necesidades del negocio [7].

La estrategia general para la ciencia de datos consiste en iterar etapas de analítica de datos con etapas de exploración y descubrimiento. En particular, se trata de descomponer al problema en partes que es factible resolver con las herramientas de analítica de datos disponibles. En algunos casos no es seguro que la herramienta disponible funcio-

ne bien, entonces validamos y evaluamos los modelos obtenidos (proceso de la analítica de datos). Si no hay éxito, tal vez sea necesario probar una herramienta de analítica de datos completamente diferente. En este proceso de ensayo y error podemos descubrir nuevo conocimiento que ayude a resolver mejor el problema (proceso de exploración y descubrimiento).

Es importante resaltar que, durante el proceso de extracción de conocimiento, son tareas relevantes las siguientes:

Identificar a los atributos informativos. Es decir, aquellos que están correlacionados con una variable de interés o que nos brindan información sobre la misma.

Ajustar un modelo paramétrico a los datos Esto mediante la selección de la función objetivo y la determinación de los parámetros que afectan a dicho objetivo.

Controlar el nivel de complejidad del modelo Mientras se logra un balance entre la capacidad de generalización y un ajuste excesivo.

Calcular la similitud Esto entre los objetos descritos por los datos.

Finalmente, debemos tener presente que las etapas en un proyecto de ciencia de datos son las mismas que las del proceso iterativo de minería de datos, a saber:

1. Comprensión del negocio y de los datos.
2. Preparación de los datos.
3. Modelación.
4. Evaluación y lanzamiento.

Bibliografía

- [1] Ana Azevedo and Manuel Filipe dos Santos. KDD, SEM-
MA and CRISP-DM: a parallel overview. *undefined*,

2008. URL <https://www.semanticscholar.org/paper/KDD-SEMMA-and-CRISP-DM-3A-a-parallel-overview-Azevedo-Santos/6bc30ac3f23d43ffc2254b0be24ec4217cf8c845>.
- [2] Joel (Software engineer) Grus. *Data science from scratch : first principles with Python*. ISBN 149190142X. URL <https://dl.acm.org/citation.cfm?id=2904392>.
- [3] Wissem Inoubli, Sabeur Aridhi, Haithem Mezni, and Alexander Jung. Big data frameworks: A comparative study. *CoRR*, abs/1610.09962, 2016. URL <http://dblp.uni-trier.de/db/journals/corr/corr1610.html#InoubliAMJ16>.
- [4] Ludmila I. Kuncheva and Christopher J. Whitaker. Pattern recognition and classification. In *Wiley StatsRef: Statistics Reference Online*. John Wiley & Sons, Ltd, Chichester, UK, sep 2014. doi: 10.1002/9781118445112.stat06503. URL <http://doi.wiley.com/10.1002/9781118445112.stat06503>.
- [5] Daniel T. Larose and Chantal D. Larose. *Discovering knowledge in data : an introduction to data mining*. ISBN 9781118874059.
- [6] Hrushikesh Mohanty, Prachet Bhuyan, and Deepak Chenthati. *Big data : a primer*. ISBN 9788132224945.
- [7] Foster Provost and Tom. Fawcett. *Data science for business*. O'Reilly, 2013. ISBN 9781449374273. URL <https://www.oreilly.com/library/view/data-science-for/9781449374273/>.
- [8] Ruili Wang, Wanting Ji, Mingzhe Liu, Xun Wang, Jian Weng, Song Deng, Suying Gao, and Chang-an Yuan. Review on mining data from multiple data sources. *Pattern Recognition Letters*, 109:120–128, jul 2018. ISSN 0167-8655. doi: 10.1016/J.

PATREC.2018.01.013. URL <https://www.sciencedirect.com/science/article/abs/pii/S0167865518300199>.

Capítulo 8

Tendencias en IA y Retos de la TD

Francisco J. Cantú Ortiz

Instituto Tecnológico y de Estudios Superiores de Monterrey

Rocío Aldeco-Pérez

Universidad Nacional Autónoma de México

Carlos Zozaya

Grupo BAL

8.1. Introducción

La Transformación Digital (TD) es un fenómeno social prevalente en el siglo 21 que tiene su génesis en la invención y crecimiento de capacidades de las computadoras digitales, de la electrónica, de las comunicaciones digitales por fibra óptica y redes inalámbricas, y sobre todo con los avances de las tecnologías de la Inteligencia Artificial (IA), particularmente con el enfoque simbólico utilizado en representación de conocimiento y razonamiento automático (KRR - *Knowledge Representation and Reasoning*). La transformación digital está trayendo cambios profundos en prácticamente todos los ámbitos de la vida de las personas y de las sociedades en general de manera global. Con el nombre

“Industria 4.0” se identifica a la revolución cibernética habilitada por el avance tecnológico y por los cambios que la transformación digital está teniendo en todo el mundo, y particularmente, en las empresas y en la empleabilidad en el siglo 21. Como antecedentes, la revolución 3.0 del siglo 20 se caracterizó por la invención de la computadora, las tecnologías de información y la automatización industrial, la cual fue precedida por la llamada revolución 2.0 a fines del siglo 19 en donde predomina la electrificación, la producción masiva, el automóvil y la aviación. La revolución 1.0 se inicia a fines del siglo 18 y principios del 19 con la invención del motor de combustión interna, a máquina de vapor, y los barcos motorizados ¹. En este capítulo abordaremos como la transformación digital está afectando no sólo la vida de las personas, sino también a la manera de hacer negocios por parte de las empresas y distintas organizaciones incluyendo a las instituciones educativas en sus distintos niveles. El motor que está impulsando estos cambios tienen a la IA como un elemento habilitador fundamental, por lo que analizaremos temas relacionados con las tendencias de la IA, así como los retos que enfrentan las empresas y las organizaciones del siglo 21 con respecto a su competitividad. Otro aspecto importante es el relacionado con las características del nuevo tipo de empleos que se tendrán en la sociedad del futuro como consecuencia de los procesos generados por la transformación digital a la que están enfrentándose las actuales y futuras generaciones. Abordaremos estos temas a continuación. Varios estudios realizados por la Asociación para el Avance de la Inteligencia Artificial (AAAI), algunas universidades como MIT y Stanford, muestran los avances de la IA en diversos dominios de aplicación mediante la utilización de plataformas, métodos y algoritmos surgidos de investigación en IA. Estos incluyen actividades cotidianas tales como el transporte urbano, los servicios de salud, y las tareas domésticas, así como del impacto que las tecnologías de IA tendrán en la sociedad hacia el año 2030. Otros estudios como los efectuados por *McKinsey*, describen las estrategias adoptadas por compañías consideradas pioneras en su campo en la utilización de tecnologías de IA como parte fundamental de sus planes de negocios y

¹https://en.wikipedia.org/wiki/Industry_4.0

de competitividad internacional. Finalmente, otros estudios realizados por organismos y fundaciones públicas, señalan el impacto que las tecnologías digitales están teniendo en la sociedad, en el empleo, y en particular, en las instituciones de educación básica y terciaria.

8.2. El Impacto de la IA en el 2030

El estudio elaborado por un panel de especialistas del proyecto One Hundred Year Study on Artificial Intelligence (AI100), organizado por la Asociación para el Avance de la Inteligencia Artificial (AAAI) y publicado en el año 2016, explica cuál es el impacto que las principales tecnologías de la IA tendrán en el contexto de la Transformación Digital así como en áreas tales como transporte público, automatización de tareas en el hogar, servicios de salud, educación, comunidades de bajos ingresos, seguridad pública, empleo y lugares de trabajo, y entretenimiento, entre los principales campos de aplicación, y del cuál presentamos aquí una síntesis así como una análisis de las implicaciones sociales y económicas [11]. Entre las tecnologías por el panel se encuentran las que surgen de la investigación en "*Large-scale machine learning, Deep learning, Reinforcement learning, Robotics, Computer vision, Natural language processing, Collaborative systems, Crowdsourcing and human computation, Algorithmic game theory and computational social choice, Internet of Things (IoT), y Neuromorphic computing*", por mencionar las tendencias actuales en investigación y su potencial de aplicación.

8.2.1. Transporte

El transporte público es uno de los primeros dominios de aplicación en los cuáles las personas deberán confiar plenamente en la capacidad de los algoritmos de IA para operar vehículos autónomos de todo tipo manejados sin intervención de conductores humanos. Un vehículo autónomo es un medio de transporte que no es operado por un conductor humano sino por un algoritmo y un conjunto de sensores y comunicaciones

inalámbricas y GPS que controlan y dirige todas las funciones de un vehículo incluyendo dirección, aceleración, frenado, cambio de carril, cálculo de ruta, estacionamiento, y servicios al conductor que incluyen reconocimiento del estado de ánimo de los pasajeros y selección de tipos de entretenimiento musical, noticias, lectura de libros, y otros servicios. Se estima que en una ciudad que opere la transportación a través de vehículos autónomos habrá menos accidentes de tráfico y aumentará considerablemente la seguridad de las personas reduciendo de manera significativa las defunciones y heridos causados por colisiones entre vehículos y atropellamientos. Esto traerá como consecuencia que las compañías de seguros tengan que replantear su modelo de negocio diseñando y ofreciendo nuevos tipos de pólizas y nuevos tipos de servicios para los conductores y empresas. También trae la necesidad de diseñar nuevas políticas y reglamentos de tránsito así como reformar el código penal y civil que regula actualmente las responsabilidades, multas, juicios, y penalizaciones por motivo de accidentes de tráfico. La *United States Department of Transportation* publicó una solicitud de propuestas en 2016 pidiendo a las ciudades de tamaño medio del país planear la infraestructura de transportación que podrían tener hacia el 2030. Para apoyar a las ciudades, entre las compañías líderes en el diseño y operación de vehículos autónomos se encuentran Google, Tesla, y Uber quienes tienen en operación diversos tipos de vehículos autónomos en varias ciudades de los Estados Unidos. Otra área de aplicación con crecimiento acelerado es el diseño y puesta en operación de drones guiados o autónomos con aplicaciones diversas que incluyen el monitoreo y optimización de los flujos de tráfico en ciudades y regiones de un país, así como aspectos de seguridad mediante la detección y el seguimiento de vehículos sospechosos de haber cometido algún delito, y la entrega de productos de diversos tipos a edificios u hogares de una región.

8.2.2. Robots de servicio

Otra aplicación con crecimiento acelerado en las últimas dos décadas es la utilización de robots de servicios en los hogares y oficinas para automatizar tareas que tradicionalmen-

te han realizado personas humanas como lo son la limpieza de piso, el corte de césped en los jardines, el lavado de la vajilla utilizada en el consumo de alimentos, la iluminación artificial de las habitaciones según las condiciones de luz natural, el monitoreo del hogar a través de cámaras y la emisión de alarmas, y la entrega de mercancías de comercios al hogar, por mencionar los principales servicios. En el año 2001 y después de un largo período de desarrollo, *Electrolux Trilobite*, una máquina con funciones de aspiradora de pisos se convirtió en el primer robot de servicio comercial. Contaba con un sistema de control para evitar obstáculos, y mecanismos de navegación. Un año después, *iRobot* lanzó *Roomba*, a un costo del 10 % del precio de *Trilobite* y con solamente 512 bytes of RAM, operó con un controlador basado en comportamiento, evitando por ejemplo, caer de unas escaleras. Desde entonces, se han vendido más de 16 millones de en todo el mundo, con funciones cada vez más inteligentes, y con el surgimiento de otros competidores. Más recientemente, se le han añadido capacidades de VSLAM (*Visual Simultaneous Location and Mapping*), una tecnología de IA desarrollada en los últimos 20 años, que le permiten al robot construir modelos del mundo tridimensionales de una casa mientras realizan tareas de limpieza siendo más eficientes en la cobertura del área de limpieza. Hay problemas actuales que son todavía temas de investigación que implican subir o bajar escaleras y lidiar con geometrías complejas en los espacios de una casa. Hay signos de que en los siguientes 15 años habrá robots de servicio con mayores capacidades. Compañías tales como Amazon y Uber están integrando tecnologías para soluciones de economías de escala. Soluciones basadas en cómputo de nube habilitarán robots domésticos con mayor funcionalidad y con algoritmos de aprendizajes accediendo a grandes bases de datos para realizar tareas más complejas. Avances en reconocimiento de voz, entendimiento de lenguaje natural, y etiquetado de imágenes habilitados por algoritmos de *Deep Learning* permitirán interacción de robots con personas en hogares y oficinas, con lo que surgirán nuevos temas éticos, de seguridad, y de privacidad.

8.2.3. Servicios de salud

La automatización de los servicios de salud en hospitales así como en los hogares con personas enfermas o con capacidades diferentes es otra de las aplicaciones crecientes de la IA. Entre los servicios actualmente en operación se encuentran los robots asistentes de enfermeras que ayudan a monitorear el estado de salud de un paciente y a proveer los medicamentos prescritos en el tiempo señalado, los robots que movilizan a personas semi o paralizadas transportándolas de la cama a una silla de ruedas y viceversa, o que las transportan a las baños y áreas de aseo y asisten a los pacientes en la higiene del paciente, así como dispositivos automatizados de asistencia en cirugías. El reto actualmente es conseguir la confianza de médicos, enfermeras y pacientes así como remover obstáculos de tipo legal, regulatorio y comercial. Los avances recientes en aprendizaje y minería de datos obtenidos de redes sociales para inferir o predecir posibles riesgos en la salud y robots para asistir a doctores en cirugías abren un panorama optimista para la aplicación de tecnologías de IA en salud. El mejorar los métodos de interacción con médicos y pacientes es un reto por abordar para expandir la utilización de la IA en aspectos de salud. Como en otros dominios, la disponibilidad de datos será un habilitador clave. Se han dado avances importantes en la recolección de datos provenientes de equipos de monitoreo personalizado, de aplicaciones móviles, y de expedientes médicos de pacientes, así como de robots que asisten con procedimientos médicos y hospitalarios.

8.2.4. Educación

El fenómeno de la transformación digital del siglo 21 está impactando no sólo las estrategias de negocio de las empresas sino que también ha tenido un efecto importante en las instituciones educativas en todos sus niveles, desde el nivel primario hasta el nivel terciario o de educación superior. Al año 2018, las generaciones que están llegando a preprimaria, primaria, secundaria, preparatoria, y educación universitaria son personas nacidas en el siglo 21. Son generaciones que han nacido en un ambiente dominado por

las tecnologías digitales que han desarrollado en ellos hábitos y habilidades diferentes las generaciones de las décadas de los 50s, 60s, 70s, 80s y posiblemente, de los 90s. Estas tecnologías incluyen el uso generalizado del internet, de los teléfonos inteligentes, las tabletas, las laptops, así como las redes sociales más populares como *WhatsApp*, *FaceBook*, *Twitter*, *You Tube*, *Instagram*, y medios de discusión como los blogs, páginas personales, y canales de videos. Tecnologías de IA tales como "*Deep Learnig*, *Image Processing*, *Natural Language Understanding*, *Planning and Scheduling*, *Machine Learning*, and *Data Mining*" se encuentran en la mayor parte de los dispositivos digitales junto con redes de sensores y GPS para sensar continuamente e interactuar con el medio ambiente. Los robots tutores que desempeñan el rol de un maestro de primaria han incrementado sus capacidades de interacción con niños y adolescentes y tendrán mayor funcionalidad e inteligencia para interactuar con personas y aprender de ellas en los próximos años. Los sistemas de tutorio inteligente también incrementarán sus capacidades para educar jóvenes de nivel preparatoria y universitario en diferentes disciplinas de conocimiento, y también tendrán un rol cada vez más destacado en el entrenamiento y desarrollo de habilidades de adultos para realizar nuevas funciones cognitivas en sus puestos de trabajo. Los sistemas de recomendación y evaluación personalizada mejorarán de manera significativa el seguimiento a estudiantes, cambiando la forma tradicional de enseñanza que conocemos al día de hoy y muy probablemente los tiempos de entrega de esta.

8.2.5. Entretenimiento

La IA ha tenido un impacto fundamental en la industria del entretenimiento. Este impacto ha sido tal, que esta industria tiene ya un nivel de generación de ingresos que los que se generan en *Hollywood*. El entretenimiento se ha transformado por el surgimiento de las redes sociales y plataformas en donde se comparten blogs, videos, fotos, y juegos mentales y de diversión, y especialmente los videojuegos disponibles tanto en lugares públicos como en dispositivos personales incluyendo teléfonos celulares y laptops. Estos medios funcionan con tecnologías de IA como son el procesamiento de lenguaje

natural, el reconocimiento de imágenes fijas y en video, imágenes tridimensionales y hologramas, y aprendizaje computacional. Los videojuegos han evolucionado a lo largo del tiempo desde los juegos que venían en la *Apple II*, los juegos de Nintendo en los 80s, hasta los juegos sofisticados ofrecido por las principales compañías como Sony, Samsung, y otras. El avance en los próximos años de esta industria, irá en crecimiento. El impacto social de los videojuegos en los niños y jóvenes del siglo 21 continúa siendo un tema activo de investigación.

8.2.6. Negocios: Estrategias Empresariales para TD y la IA

Estadísticas elaboradas por la *International Telecommunication Union* (ITU) muestran que en el 2017 existen cerca de 4 billones de usuarios de internet en todo el mundo, lo cual representa alrededor del 50 % de la población mundial ². Por otro lado, el crecimiento del comercio electrónico a nivel global sigue teniendo un crecimiento acelerado, con lo cual se abren grandes oportunidades para las empresas en la comercialización de sus servicios y productos a escala mundial ³. En esta sección presentamos una síntesis de las principales estrategias que están siguiendo empresas mundiales líderes en tecnologías y pioneras en el uso y aplicación de tecnologías de IA para el despliegue de sus operaciones. La fuente de estos estudios son estudios realizados por la consultora *McKinsey* así como estudios efectuados por escuelas de negocios de algunas universidades. En este año 2018, *McKinsey* desplegó un estudio sobre las empresas que ya han identificado a la IA como una tecnología estratégica para sus planes de competitividad global y de aquellas empresas que se han quedado atrás en la adopción de la IA. Entre las que destacan por el uso de IA se encuentran la industria financiera, la de telecomunicaciones, automotriz, energía, transporte, y servicios de salud. También señala las limitaciones y los problemas técnicos a resolver en IA para incrementar su penetración en la industria [1, 7]. También reporta que la adopción de tecnologías por parte del mercado sigue una

²<https://www.internetworldstats.com>

³https://en.wikipedia.org/wiki/E-commerce#Global_trends

curva en forma de “S” donde al principio destacan las empresas líderes en tecnología, y al reconocer las ventajas, surge una pléyade de seguidores que tratan de mantenerse en el negocio, hasta que la tecnología cumple su ciclo de vida. En este proceso, el estudio revela que las empresas que cuentan con una sólida estructura digital y de uso y aplicación de IA en sus operaciones usando el enfoque simbólico, conexionista, evolutivo, y otros enfoques que se han popularizado en las últimas décadas (Agentes inteligentes, *Deep Learning*, reconocimiento de voz, procesamiento de imágenes y lenguaje natural, robótica, algoritmos genéticos, etc), son las que llevan la ventaja [4]. En el reporte publicado por *McKinsey Global Institute* en abril del 2018 sobre más de 400 casos de uso a lo largo de 19 sectores industriales y nueve áreas estratégicas de negocio, revela el uso generalizado y el potencial económico para las empresas que están aplicando tecnologías de IA en sus operaciones, y en particular, las técnicas de *Deep Learning*. La metodología contempla cuatro pasos: (1) Mapeo de las tecnologías de IA a diferentes tipos de problemas, (2) Aprendizajes de los casos de uso con tecnologías de IA, (3) Estimación del beneficio económico potencial para las organizaciones estimándolos entre 3.5 y 5.4 trillones de dólares, y (4) el mapa de ruta para la creación de impacto y valor [8]. Otro estudio elaborado por *McKinsey* revela que la prevención de fraude en operaciones financieras es una de las mayores preocupaciones de las empresas comerciales. El reporte "2015/16 Global fraud report." elaborado por *Kroll* and *The Economist Intelligence Unit* estima que alrededor del mundo el 75 % de las compañías encuestadas han sido víctimas de fraude durante el año anterior creciendo 14 % con respecto a los últimos tres años. La encuesta del 2016 "Payments Fraud and Control Survey" de la *Association for Financial Professionals* encontró que el 73 % de los profesionales financieros reportaron intentos de fraude o fraude completos en el 2015. Ante esta situación, el estudio de *McKinsey* reporta cómo es que técnicas avanzadas de analítica de datos pueden aplicarse en las organizaciones de la industria de servicios financieros para anticipar y prevenir el fraude. El estudio también reporta las metodologías y herramientas basadas en aprendizaje

computacional que varias empresas han desarrollado y aplicado para proteger sus activos financieros [6].

8.3. Empleo y lugares de trabajo

La IA, las tecnologías digitales, y la automatización están teniendo ya un efecto al desplazar de sus puestos a trabajadores que típicamente realizan trabajos manuales y repetitivos. Un estudio realizado por Richard y Daniel Susskind y publicado por *Harvard Business Review* afirma que las tecnologías de IA reemplazarán no solo trabajos manuales rutinarios, sino que ya están reemplazando a médicos, abogados, contadores, y otras profesiones. Y proporciona estadísticas del número de personas que están accediendo servicios médicos, legales y fiscales a través de diferentes portales Web que se ofrecen al público Estadounidense [12]. En el estudio realizado en el *MIT Sloan School of Management* en colaboración con el *Boston Consulting Group (BCG) Henderson Institute*, *Sam Ransbotham* y colegas presentan el perfil de las empresas pioneras que están no solo utilizando sino escalando a gran escala las tecnologías de IA en sus estrategias de negocios. Ellos abordan sobre los siguientes aspectos de las empresas pioneras: (1) Reforzamiento de su compromiso con la utilización de IA en sus áreas funcionales, (2) Escalamiento del uso de las tecnologías de IA en todos los niveles de la organización, (3) Priorizar la generación de beneficios sobre ahorro de costos, y (4) la creación de sentimientos de temor y esperanza entre los trabajadores de la organización, y terminan documentando los mitos y realidades sobre las tecnologías de IA. La encuesta aplicada a 3,076 ejecutivos de empresa y 36 entrevistas personales a profundidad clasifican a las empresas en términos de su compromiso con la adopción de IA en pioneras, exploradoras, experimentales, y pasivas. Con respecto a la adopción de IA en la empresa, el 86 % de los entrevistados creen que los empleados tendrán que cambiar y actualizar sus habilidades para realizar las funciones de su puesto, 82 % estima que la productividad de la empresa mejorará y que los trabajadores incrementarán sus habilidades, mientras

que el 47 % cree que el número de empleos se reducirá pero el mismo porcentaje piensa que los empleos se mantendrán y aún aumentarán, pero requiriendo nuevas habilidades por parte de los empleados [10]. En otros estudios recientes sobre el impacto de la IA en los negocios, en el empleo, y en la sociedad que abordan los temas antes expuestos, incluyen el realizado por Alexandra Suich Baas y publicado por la revista *The Economist* en marzo del 2018. Entre los casos que reporta se encuentra la predicción de inventarios para ventas masivas como las que realiza Amazon, los servicios al cliente (*help desks*) para atender de manera rápida y amable a clientes que llaman para solicitar productos o consultas sobre funciones o fallas de producto, la contratación de empleados por parte de las empresas, y el asegurar condiciones óptimas de trabajo y seguridad en las empresas. Termina señalando los retos por resolver en IA y las consecuencias de hacer una mal manejo y uso de las tecnologías de IA en las organizaciones [3].

8.4. IA en la TD de las Organizaciones

Como se indicó en la Introducción de este capítulo, la Transformación Digital es un fenómeno que está afectando de manera profunda a todo tipo de organizaciones y a la sociedad en general. La Inteligencia Artificial está teniendo un papel protagónico como uno de los principales habilitadores de dicha transformación. Rogers (2016) [9] señala que existen cinco dominios de una organización que se ven impactados por la transformación digital: clientes, competencia, datos, innovación y valor. A continuación, se mencionan algunos impactos de la Inteligencia Artificial (IA) en cada uno de estos dominios para apoyar la transformación digital de una organización:

Impactos en el dominio de clientes La transformación digital en este dominio implica que la organización deje de ver a sus clientes como un mercado masivo al cual se le venden productos o servicios de manera unidireccional, y entienda que para tener éxito se debe estar en permanente contacto con ellos brindándoles valor. Para ello, la IA puede ayudar a entender y segmentar mejor a los clientes de tal

forma que las comunicaciones y el contenido que se les brinda se más relevante para cada uno de ellos y esto fortalezca la relación con ellos.

Impactos en el dominio de competencia La transformación digital en este dominio implica que la organización deje de ver la competencia como un juego de suma cero y establezca modelos de negocio de plataforma y/o alianzas con otros competidores o complementadores para en conjunto dar un mayor valor a los clientes. Los algoritmos de IA juegan un papel muy importante para habilitar el modelo de negocio de plataforma ayudando a hacer una mejor mancuerna entre los proveedores y receptores de los servicios correspondientes.

Impactos en el dominio de datos Las empresas tradicionalmente se han gestionado únicamente con base en datos estructurados; sin embargo, la mayor parte de los datos con los que cuentan las organizaciones son no estructurados. La IA ha desarrollado algoritmos de tipo cognitivo que permiten aprovechar los datos no estructurados y que están teniendo un gran impacto para mejorar la toma de decisiones.

Impactos en el dominio de innovación Si bien la innovación ha sido concebida como una fuente importante de crecimiento rentable desde hace muchos años, en los últimos años la innovación se ha vuelto más “abierto” para aprovechar el talento que se encuentra fuera de la organización, y la experimentación se ha convertido en el mecanismo más efectivo para innovar. Diversas técnicas de IA y de computación evolutiva pueden utilizarse para robustecer el aprendizaje derivado de dichos experimentos y para identificar patrones que den como resultado un mayor valor para los clientes.

Impactos en el dominio de valor La transformación digital en este dominio tiene que ver con que el concepto de valor se vuelve más dinámico e individual. Por medio de sus capacidades analíticas, la IA puede ayudar a una organización a identificar aquellos elementos de la experiencia del cliente que han dejado de tener valor

con miras a que la empresa reinvente a tiempo la propuesta de valor a sus clientes. O bien ayudar a optimizar el valor que se da un cliente haciendo una mejor selección del contenido que se le ofrece (por ejemplo, mediante algoritmos de recomendación de contenido como los que usan Netflix o Amazon).

8.5. Adopción de la IA en las Organizaciones

Como se indicó anteriormente, un estudio reciente sobre el uso de la IA en las organizaciones [10] revela que existen distintos patrones de adopción de esta tecnología en las empresas. El estudio agrupa las organizaciones en función de qué tan bien entienden la organización a la Inteligencia Artificial y de qué tanto han avanzado en su adopción. Un hallazgo importante es que las organizaciones que han sido pioneras en la adopción de IA (i.e., aquéllas que mejor entienden esta tecnología y que han avanzado más en su adopción) están invirtiendo más en IA, haciendo esfuerzos por escalar IA (y requieren una buena estrategia para lograrlo), y se enfocan en aplicaciones para generar ingresos más que en reducir costos. Lo anterior parecería indicar que las inversiones anteriores en IA están dando los frutos esperados y que ello está ayudando a distinguir a la organización de sus competidores. Algunos otros hallazgos del reporte del MIT y BCG [10] son los siguientes:

1. La “madurez” de los datos es el impulsor principal de la Inteligencia Artificial. Los pioneros en la adopción de IA consideran a los datos como un activo estratégico y reportan los temas de datos a nivel ejecutivo.
2. Las principales barreras para la adopción de la Inteligencia Artificial son la falta de talento, la falta de liderazgo para impulsar iniciativas y la dificultad de elaborar un caso de negocios que justifique la inversión en esta tecnología.

3. La diferencia para el éxito la hace el que la Alta Dirección esté consciente y entusiasmada sobre el potencial que las tecnologías de IA podrían tener para la organización.
4. La IA está generando valor real en múltiples organizaciones (no sólo demostraciones de laboratorio en empresas de tecnología).
5. Las empresas pioneras, es decir aquellas que entienden mejor la IA y que han avanzado más en su adopción, están invirtiendo más en IA y alejándose del resto.
6. Las empresas pioneras están creando estrategias para escalar la IA a toda la organización.

Las empresas pioneras están aplicando IA para desarrollar nuevas ofertas que se traducen en mayores ingresos.

8.6. Tendencias en IA y Retos de la TD en México

Las instituciones Mexicanas de los sectores público, privado y educativo no están exentas del fenómeno de la IA y la Transformación Digital. En un artículo comisionado por la Embajada Británica en México y financiado por *The Prosperity Fund* y apoyado por *Oxford Insights* and *C Minds*, se hace un análisis detallado de la situación de la IA en México y de las oportunidades que se presentan para las instituciones de los sectores público, productivo, educativo, y social en aspectos de competitividad y aprovechamiento de las ventajas que traen las tecnologías de la IA para estas instituciones [5]. El reporte presenta un análisis sobre la importancia de adoptar las tecnologías de IA en México, el rol que el gobierno Mexicano debe jugar en esta transformación, las bases que deben establecerse para desarrollar una estrategia digital, los cambios legislativos que se deben impulsar en telecomunicaciones, en propiedad intelectual, en protección y privacidad

de los datos, así como una descripción del trabajo académico en IA que se lleva a cabo en las principales instituciones del país. Presenta varios estudios en innovación regional en varios estados y ciudades del país, y termina con una serie de recomendaciones para el gobierno en áreas de legislación, infraestructura, financiamiento, educación, así como regulaciones éticas. Un estudio conducido por Narayan Ammachichi sitúa a México entre los primeros 25 países que están explorando los beneficios de la AI e integrando automatización inteligente en sus economías de acuerdo al *Automation Readiness Index* elaborado por la unidad de inteligencia del *Economist*. El estudio argumenta que México grandes avances en impulsar a los negocios y a los estudiantes para aprovechar los beneficios de la IA. Varias compañías tecnológicas extranjeras están contactando universidades Mexicanas para contratar alumnos de ingeniería con talento para desarrollar soluciones basadas en IA [2]. Por ejemplo, según este estudio, *Nvidia*, una compañía situada en *Silicon Valley*, ha ido un paso más adelante negociando con Pemex acerca del uso de tecnología de IA para reforzar los sistemas de producción y mejorar la eficiencia de los procesos. También, la compañía *Wizeline* especializada en soluciones basadas en experiencia con clientes y en productos digitales ha lanzado una academia de IA en Guadalajara para ofrecer capacitación en IA y tecnologías relacionadas. Estos ejemplos dan una idea de cómo la IA está posicionándose en el país como una tecnología que ofrecerá ventajas competitivas para las instituciones que desarrollen planes estratégicos para su adopción, desarrollo, y uso.

8.7. Conclusión

Presentamos ahora una síntesis de los diferentes temas que se han abordado y que han presentado un panorama de las principales tecnologías de IA enfatizando aquellas que utilizan el enfoque simbólico basado en la lógica, la probabilidad, y la representación del conocimiento. Los enfoques de la lógica comprenden la lógica proposicional y de primer orden, el razonamiento bajo incertidumbre, el razonamiento causal, el razona-

miento semántico, y la minería de datos. Aunque en la actualidad los sistemas proposicionales, lógicos y lingüísticos no son muy populares, debido principalmente al auge del aprendizaje automático, este tipo de representaciones seguirán siendo de gran utilidad especialmente cuando se requiera transparentar lingüísticamente la cadena inferencial y las relaciones entre los efectos y sus causas. Los modelos probabilísticos, por su parte, tendrán un campo de aplicación muy amplio en problemas con incertidumbre, incluyendo aplicaciones en la salud, el sector energía, juegos (serios y de entretenimiento), robótica de servicio, etc. Otra área con gran dinamismo es la de los modelos gráficos causales, que no sólo representan relaciones de dependencia estadística sino también relaciones causa-efecto. En México se empieza a incursionar en esta área en el modelado de las relaciones de conectividad efectiva en el cerebro mediante redes bayesianas causales, así como en modelos predictivos para la detección temprana de fragilidad en los adultos mayores. Un área más en desarrollo es la combinación de representaciones basadas en la lógica de predicados y representaciones probabilistas, con el fin de capitalizar las bondades de ambos sistemas: alta expresividad y manejo de incertidumbre. Estas representaciones tienen diversas variantes y se conocen como modelos relacionales probabilistas. En México se han aplicado al reconocimiento de objetos en imágenes. Una de las tendencias principales en las propuestas de sistemas basados en agentes es la integración con ambientes de cómputo ubicuo e Internet de las Cosas (IoT, por sus siglas en inglés). Los escenarios del cómputo ubicuo, en que múltiples procesadores y sensores están integrados al ambiente, proveen servicios de manera transparente, pero se requiere coordinarlos de forma distribuida, siguiendo los métodos de los sistemas multi-agentes, tales como la negociación. Por ejemplo, la generación actual de domótica, basada en dispositivos conectados que se controlan por medio del celular y de reglas simples pronto llegará a su límite —no podemos controlar 50 dispositivos de forma centralizada si hay interacciones complejas entre ellos— y será necesario emplear un enfoque de delegación, típico de los agentes inteligentes. Al pasar del Internet de los usuarios humanos al IoT se abren grandes oportunidades. Para abordar esta problemática se integró la línea

de investigación "Sistemas Ubicuos Multiagentes" de la Red Temática RedTIC desde el 2011 en la que participaron varios miembros de Amexcomp. Otra tarea pendiente es el diseño e implementación de procesos autónomos denominados agentes ontológicos para modelar y recuperar información disponible en repositorios digitales y resolver los problemas de interoperabilidad semántica. Aunque la investigación sobre ontologías y modelos basados en grafos ha sido intensa durante varias décadas todavía queda mucho por hacer. Particularmente, es necesario realizar mayor experimentación y explorar más profundamente las propuestas de modelado del conocimiento aplicadas a grandes volúmenes de datos como los disponibles en Internet. Finalmente, concluimos este capítulo señalando solamente el gran impacto que las tecnologías de IA están teniendo en la sociedad al convertirse en el motor de la revolución y transformación digital así como la Industria 4.0 prevalentes en el siglo 21, señalando también que aunque ha habido avances sobresalientes en la IA, subsisten aún innumerables retos científicos y tecnológicos que serán objeto de investigación por la presente y futuras generaciones, .

Bibliografía

- [1] Ajay Agrawal, Joshua Gans, and Avi Goldfarb. *The economics of artificial intelligence : an agenda*. ISBN 022661333X. URL https://books.google.com.mx/books/about/The_{ }Economics_{ }of_{ }Artificial_{ }Intelligence.html?id=OmyVDwAAQBAJ-&source=kp_{ }book_{ }description{&}redir_{ }esc=y.
- [2] Narayan Ammachichi. Mexico among the top 25 countries for artificial intelligence. 2019. URL <http://www.mexico-it.net/mexico-among-top-25-countries-for-artificial-intelligence-study>.
- [3] Alexandra Suich Baas. Grait expectations. March 2018.

- [4] Jacques Bughin and Nicolas Van Zeebroeck. Artificial intelligence: Why a digital base is critical. July 2018.
- [5] Cristina Martinez Emma Martinho-Truswell, Hannah Miller, Isak Nti Asare, André Petheram, Richard Stirling, and Constanza Gómez Mont. TOWARDS AN AI STRATEGY FOR MEXICO — Oxford Insights, 2018. URL <https://www.oxfordinsights.com/mexico>.
- [6] Carlo Giovine Giacomo Corbo and Chris Wigley. Applying analytics in financial institutions' fight against fraud. April 2017.
- [7] James Manyika Michael Chui and Mehdi Merimadi. What ai can do and can't (yet) do for your business. 2018 January.
- [8] Mehdi Merimadi Nicolaus Henke Rita Chung Pieter Net Michael Chui, James Manyika and Sankalp Malhotra. Notes from the ai frontier: Applications and value of deep learning. 2018 January.
- [9] D. L. Rogers. *The Digital Transformation Playbook. Rethink your business for the digital age*. Columbia Business School, 2016.
- [10] M. Reeves D. Kiron S. Ransbotham, P. Gerbert and M. Spira. Artificial intelligence in business gets real. September 2018.
- [11] Stanford University. One Hundred Year Study on Artificial Intelligence (AI100) |, 2016. URL <https://ai100.stanford.edu/>.
- [12] Richard Susskind and Daniel Susskind. Technology will replace many doctors, lawyers and other professionals. 2016 October.

Conocimiento y Razonamiento Computacional, se terminó el 30 de septiembre de 2019.

A partir del 1 de diciembre de 2019 está disponible en formato PDF en la
página de la Academia Mexicana de Computación:

<http://www.amexcomp.mx>